



# POSGRADOS

## MAESTRÍA EN PRODUCCIÓN Y OPERACIONES INDUSTRIALES

RPC-SO-30-No.506-2019

OPCIÓN DE  
TITULACIÓN:

PROYECTOS DE DESARROLLO

TEMA:

APLICACIÓN DE REDES NEURONALES EN OPERACIONES INDUSTRIALES  
DE MANUFACTURA PARA PRODUCTOS PRISMÁTICOS CIRCULARES EN  
MATERIALES METÁLICOS NO FERROSOS

AUTOR:

ALEXANDER WLADIMIR AGUIRRE AGUIRRE

DIRECTOR:

VACA MICHILENA EDUARDO XAVIER

QUITO - ECUADOR  
2021

***Autor/a:***



***Alexander Wladimir Aguirre Aguirre***

Ingeniero Mecánico

Candidato a Magíster en Maestría en Producción y Operaciones Industriales por la Universidad Politécnica Salesiana – Sede Quito.

aaguirreag@est.ups.edu.ec

***Dirigido por:***



***Eduardo Xavier Vaca Michilena***

Ingeniero Mecánico

Magíster en Manufactura y Diseño Asistido por Computador

xvaca@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2021 Universidad Politécnica Salesiana.

QUITO – ECUADOR – SUDAMÉRICA

AGUIRRE AGUIRRE ALEXANDER WLADIMIR

***APLICACIÓN DE REDES NEURONALES EN OPERACIONES  
INDUSTRIALES DE MANUFACTURA PARA PRODUCTOS PRISMÁTICOS  
CIRCULARES EN MATERIALES METÁLICOS NO FERROSOS***

## RESUMEN

Actualmente en el Ecuador, el mercado ha dado acogida al mecanizado de varios materiales metálicos, en especial los no ferrosos como las aleaciones de aluminio con tratamiento térmico de la familia 6xxx y 7xxx, para hacer productos primaticos circulares. La presente investigación tiene como objetivo el estudio de la integridad superficial y la tabulación del caudal de material removido aplicando aprendizaje no supervisado (reglas de asociación y agrupación) y supervisado (red neuronal artificial) en el proceso de manufactura en un torno CNC para mecanizar los ejes de aluminio. Se utilizo dos parámetros de corte constantes, como lo son la velocidad de corte de 420 m/min y volumen de material removido de 22.2 cm<sup>3</sup>. Previo al proceso de mecanizado se hicieron simulaciones utilizando software de manufactura y diseño asistido por computador para hacer un análisis comparativo con el tiempo real en el procesamiento de cada ensayo, determinando la correlación de los datos censados. En el desarrollo del aprendizaje no supervisado se estudió la correlación de los parámetros de corte y se diseñó el algoritmo de agrupamiento en función del valor máximo del análisis de Elbow, concluyendo que para estudiar los resultados de la aleación de aluminio AA 7075 T6, se necesita un arreglo ortogonal de veinte y siete niveles. Para el análisis neuronal se clasifico los resultados de la rugosidad superficial utilizando la escala Likert de cinco niveles (baja, regular, buena, muy buena y excelente) y en la estructura de la neurona se formuló en función de la profundidad, avance y velocidad de corte; presentando eficiencia del 75% en la arquitectura del avance de corte y la profundidad en la tabla de materiales AA 6061 T6 y AA 7075 T6 y eficiencia del 100% en la arquitectura del avance de corte y la profundidad en la tabla del material AA 6061 T6.

**Palabras claves:** Red neuronal, inteligencia artificial, red neuronal artificial, integridad superficial, rugosidad, aplicaciones neuronales.

## ABSTRACT

Currently in Ecuador, the market has welcomed the machining of various metallic materials, especially non-ferrous ones such as aluminum alloys with heat treatment of the 6xxx and 7xxx families, to make circular primary products. The present research aims to study the surface integrity and the tabulation of the flow of removed material applying unsupervised learning (association and grouping rules) and supervised (artificial neural network) in the manufacturing process on a CNC lathe to machine the aluminum shafts. Two constant cutting parameters were used, such as the cutting speed of 420 m / min and the volume of material removed of 22.2 cm<sup>3</sup>. Before the machining process, simulations were made using computer-aided design and manufacturing software to make a comparative analysis with real time in the processing of each test, determining the correlation of the census data. In the development of unsupervised learning, the correlation of the cutting parameters was studied and the clustering algorithm was designed based on the maximum value of the Elbow analysis, concluding that to study the results of the aluminum alloy AA 7075 T6, it is necessary an orthogonal arrangement of twenty-seven levels. For the neuronal analysis, the results of the surface roughness were classified using the Likert scale of five levels (low, regular, good, very good and excellent) and in the structure of the neuron it was formulated according to the depth, advance and speed of court; presenting 75% efficiency in the architecture of the cutting feed and depth in the AA 6061 T6 and AA 7075 T6 material table and 100% efficiency in the architecture of the cutting feed and depth in the AA 6061 T6 material table.

**Keywords:** Neural network, artificial intelligence, artificial neural network, surface integrity, roughness, neural applications.

## **AGRADECIMIENTO**

Un gran agradecimiento a la Universidad Politécnica Salesiana, por la oportunidad de la formación académica durante el periodo de la pandemia mismos que son plasmados en la investigación.

Al Ingeniero William Quitiaquez M.Sc, profesor y amigo, por sus enseñanzas, aliento y respaldo en el desarrollo profesional.

Al Ingeniero Xavier Vaca M.Sc, amigo y tutor, quien apostó por el desarrollo de una idea y fue guía para el progreso de la misma.

*Ing. Alexander Aguirre*

## **DEDICATORIA**

A mi padre, quien es mi apoyo y ayuda en los momentos difíciles; la persona que me enseñó a aprender del pasado, me prepare en el presente para crear mi futuro; me oriento en toda mi vida y siempre está para mí cuando más lo necesito.

Gracias.

## ÍNDICE DE CONTENIDO

<b>RESUMEN.....</b>	<b>iii</b>
<b>ABSTRACT .....</b>	<b>iv</b>
<b>AGRADECIMIENTO .....</b>	<b>v</b>
<b>DEDICATORIA .....</b>	<b>vi</b>
<b>ÍNDICE DE CONTENIDO .....</b>	<b>vii</b>
<b>ÍNDICE DE FIGURAS.....</b>	<b>ix</b>
<b>ÍNDICE DE TABLAS.....</b>	<b>xii</b>
<b>ÍNDICE DE ANEXOS .....</b>	<b>xiii</b>
<b>NOMENCLATURA.....</b>	<b>xiv</b>
<b>INTRODUCCIÓN .....</b>	<b>1</b>
<b>PLANTEAMIENTO DEL PROBLEMA.....</b>	<b>2</b>
<b>FORMULACIÓN DEL PROBLEMA .....</b>	<b>2</b>
<b>OBJETO DE ESTUDIO .....</b>	<b>3</b>
<b>JUSTIFICACIÓN DE LA INVESTIGACIÓN .....</b>	<b>3</b>
<b>OBJETIVOS.....</b>	<b>5</b>
<b>Hipótesis de la investigación.....</b>	<b>6</b>
Hipótesis nula ( $H_0$ ) .....	6
Hipótesis alternativa. ( $H_i$ ) .....	6
<b>Alcance .....</b>	<b>6</b>
<b>Descripción de la estructura de los capítulos del proyecto de investigación .....</b>	<b>7</b>
<b>CAPÍTULO 1.....</b>	<b>8</b>
<b>MARCO CONTEXTUAL Y TEÓRICO SOBRE EL ANÁLISIS DE LA FORMULACIÓN DE ALGORITMOS.....</b>	<b>8</b>
1.1    Introducción.....	8
1.2    Marco teórico de la investigación.....	8
1.2.1    Antecedentes de la investigación.....	8
1.2.2    Prologo .....	8
1.2.2.1    Parámetros de mecanizado.....	8
1.2.2.2    Análisis de reconocimiento de patrones .....	12
1.2.2.3    Paradigmas del Machine Learning .....	13
1.2.2.4    Distancia .....	14
1.2.2.5    Escalamiento multidimensional.....	17
1.2.2.6    Algoritmo K-means .....	18
1.2.2.7    Algoritmo Jerárquico .....	18
1.2.2.8    Algoritmo de Elbow.....	20
1.2.2.9    Métodos de validación interna.....	21
1.2.2.10    Métodos de validación externa .....	23
1.2.3    Costo de mecanizado .....	26
1.2.3.1    Costo de consumo de energía $C_e$ .....	26
1.2.3.2    Costos generales .....	27
1.2.3.3    Costos de la herramienta $C_t$ .....	28
1.2.4    Multi clasificadores para control de la producción .....	28
1.2.4.1    Antecedentes .....	29

1.2.4.2 Red neuronal artificial .....	29
1.2.4.3 Ventajas .....	30
1.2.4.4 Modelo de McCulloch & Pitts .....	30
1.2.4.5 Perceptrón .....	31
1.2.4.6 ADALINE: Adaptive Linear Neuron .....	32
1.2.4.7 Redes Neuronales Artificiales RNA (Hecht - Nielssen).....	33
1.3 Fundamentación de la investigación .....	33
1.3.1 Fundamentación legal.....	36
1.4 Aspectos teóricos fundamentales .....	37
<b>CAPÍTULO 2.....</b>	<b>38</b>
<b>METODOLOGÍA DE LA INVESTIGACIÓN .....</b>	<b>38</b>
2.1. Introducción.....	38
2.2. Diseño de la investigación.....	39
2.2.1. Análisis del proceso de mecanizado .....	39
2.2.2. Programación en RStudio .....	43
2.3. Modalidad de la investigación.....	51
2.4. Tipo de investigación .....	51
2.5. Métodos de investigación.....	51
2.6. Técnicas e instrumentos .....	51
2.6.1. Técnicas.....	51
2.6.2. Instrumentos.....	51
2.7. Operacionalización de las variables .....	55
2.7.1. Variable dependiente.....	55
2.7.2. Variable independiente.....	56
2.8. Población y muestra .....	56
2.8.1. Población.....	56
2.8.2. Muestra.....	56
2.9. Resultados de la técnica aplicada .....	57
<b>CAPÍTULO 3.....</b>	<b>59</b>
<b>ANÁLISIS E INTERPRETACIÓN DE RESULTADOS .....</b>	<b>59</b>
3.1. Introducción.....	59
3.2. Descripción de la situación actual .....	59
3.2.1. Análisis de resultados del proceso de mecanizado .....	59
3.2.2. Análisis de resultados en función del tiempo.....	60
3.2.3. Análisis de clustering .....	65
3.2.4. Análisis de red neuronal.....	80
3.2.5. Análisis de financiero.....	88
<b>CONCLUSIONES.....</b>	<b>91</b>
<b>RECOMENDACIONES.....</b>	<b>92</b>
<b>REFERENCIAS.....</b>	<b>93</b>
<b>ANEXOS .....</b>	<b>102</b>



## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Velocidad de corte .....	9
<b>Figura 2.</b> Profundidad .....	10
<b>Figura 3.</b> Avance de la herramienta .....	10
<b>Figura 4.</b> Caudal de material removido.....	11
<b>Figura 5.</b> Rugosidad de una superficie.....	11
<b>Figura 6.</b> Tiempo de mecanizado .....	11
<b>Figura 7.</b> Distancia Euclidiana .....	16
<b>Figura 8.</b> Distancia de Manhattan .....	17
<b>Figura 9.</b> Algoritmo K-means .....	18
<b>Figura 10.</b> Algoritmo DHC .....	19
<b>Figura 11.</b> Clasificación del algoritmo Jerárquico .....	19
<b>Figura 12.</b> Algoritmo de Elbow .....	21
<b>Figura 13.</b> Coeficiente de Silueta.....	22
<b>Figura 14.</b> Neurona artificial .....	30
<b>Figura 15.</b> Neurona de McCulloch & Pitts .....	31
<b>Figura 16.</b> Perceptrón.....	31
<b>Figura 17.</b> Esquema ADALINE.....	32
<b>Figura 18.</b> Esquema de una RNA .....	33
<b>Figura 19.</b> Árbol de problemas “Redes neuronales” .....	34
<b>Figura 20.</b> Árbol de problemas “Calidad superficial” .....	35
<b>Figura 21.</b> Diagrama causa - efecto .....	36
<b>Figura 22.</b> Proceso de refrendado .....	39
<b>Figura 23.</b> Base de probeta perforada .....	40
<b>Figura 24.</b> Decalaje de la probeta.....	40
<b>Figura 25.</b> Parámetros para configuración de insertos .....	41
<b>Figura 26.</b> Parámetro, Geometría de la pieza.....	41
<b>Figura 27.</b> Parámetro, Tecnología de mecanizado .....	42
<b>Figura 28.</b> Mecanizado de probeta.....	42
<b>Figura 29.</b> Medición de rugosidad de ensayo .....	43
<b>Figura 30.</b> Rugosímetro Mitutoyo SJ 210.....	52
<b>Figura 31.</b> Porta herramienta SDJCR 2020 K11 .....	52
<b>Figura 32.</b> Inserto de corte DCGX 11T304-AL H10 (CVD).....	53
<b>Figura 33.</b> Inserto de corte DCGX 11T304-AL H10 (PVD) .....	53
<b>Figura 34.</b> Probeta AA 7075 – T6.....	54
<b>Figura 35.</b> Probeta AA 6061 – T6.....	54
<b>Figura 36.</b> Comparativa temporal .....	61
<b>Figura 37.</b> Rugosidad en función del número de ensayo .....	62
<b>Figura 38.</b> Tiempo de mecanizado en función del número de ensayo.....	62
<b>Figura 39.</b> Rugosidad en función de la Profundidad.....	63
<b>Figura 40.</b> Rugosidad en función del avance .....	63
<b>Figura 41.</b> Caudal en función del avance.....	64
<b>Figura 42.</b> Rugosidad en función de la profundidad.....	64
<b>Figura 43.</b> Matriz de correlación AA 6061 T6 .....	65
<b>Figura 44.</b> Rugosidad en función del ensayo – AA 6061 T6.....	66

<b>Figura 45.</b> Algoritmo K-means - AA 6061 T6.....	66
<b>Figura 46.</b> Dendograma AA 6061 T6 .....	67
<b>Figura 47.</b> Algoritmo de elbow AA 6061 T6.....	67
<b>Figura 48.</b> Coeficiente de silueta K-means AA 6061 T6.....	68
<b>Figura 49.</b> Coeficiente de silueta DHC, AA 6061 T6.....	69
<b>Figura 50.</b> Matriz de correlación AA 7075 T6 .....	70
<b>Figura 51.</b> Rugosidad en función del ensayo – AA 7075 T6.....	70
<b>Figura 52.</b> Algoritmo K-means – AA 7075 T6.....	71
<b>Figura 53.</b> Dendograma AA 7075 T6 .....	71
<b>Figura 54.</b> Algoritmo de Elbow – AA 7075 T6 .....	72
<b>Figura 55.</b> Coeficiente de silueta K-means – AA 7075 T6.....	73
<b>Figura 56.</b> Coeficiente de silueta DHC – AA 7075 T6.....	74
<b>Figura 57.</b> Matriz de correlación conjunta .....	75
<b>Figura 58.</b> Rugosidades en función de los ensayos.....	76
<b>Figura 59.</b> Algoritmo K-means .....	76
<b>Figura 60.</b> Dendograma.....	77
<b>Figura 61.</b> Algoritmo de Elbow .....	78
<b>Figura 62.</b> Coeficiente de silueta K-means .....	79
<b>Figura 63.</b> Coeficiente de silueta DHC .....	79
<b>Figura 64.</b> Arquitectura Vc-fn-ap, AA 6061 T6 .....	80
<b>Figura 65.</b> Arquitectura Vc-fn, AA 6061 T6 .....	81
<b>Figura 66.</b> Arquitectura Vc-ap, AA 6061 T6.....	81
<b>Figura 67.</b> Arquitectura fn-ap, AA 6061 T6 .....	82
<b>Figura 68.</b> Arquitectura Vc-fn-ap, AA 7075 T6 .....	83
<b>Figura 69.</b> Arquitectura Vc-fn, AA 7075 T6 .....	83
<b>Figura 70.</b> Arquitectura Vc-ap, AA 7075 T6.....	84
<b>Figura 71.</b> Arquitectura fn-ap, AA 7075 T6 .....	85
<b>Figura 72.</b> Arquitectura Vc-fn-ap.....	85
<b>Figura 73.</b> Arquitectura fn-ap.....	86
<b>Figura 74.</b> Arquitectura Vc-ap .....	87
<b>Figura 75.</b> Arquitectura Vc-fn.....	87
<b>Figura 76.</b> Configuración de herramienta DNMG .....	103
<b>Figura 77.</b> Configuración de herramienta DCGX (CVD).....	103
<b>Figura 78.</b> Configuración de herramienta DCGX (PVD) .....	103
<b>Figura 79.</b> Listado de ensayos.....	104
<b>Figura 80.</b> Geometría del ensayo 1 .....	104
<b>Figura 81.</b> Tecnología del ensayo 1 .....	104
<b>Figura 82.</b> Geometría del ensayo 2 .....	104
<b>Figura 83.</b> Tecnología del ensayo 2 .....	105
<b>Figura 84.</b> Geometría del ensayo 3 .....	105
<b>Figura 85.</b> Tecnología del ensayo 3 .....	105
<b>Figura 86.</b> Geometría del ensayo 4 .....	105
<b>Figura 87.</b> Tecnología del ensayo 4 .....	106
<b>Figura 88.</b> Geometría del ensayo 5 .....	106
<b>Figura 89.</b> Tecnología del ensayo 5 .....	106
<b>Figura 90.</b> Geometría del ensayo 6 .....	106

<b>Figura 91.</b> Tecnología del ensayo 6 .....	107
<b>Figura 92.</b> Geometría del ensayo 7 .....	107
<b>Figura 93.</b> Tecnología del ensayo 7 .....	107
<b>Figura 94.</b> Geometría del ensayo 8 .....	107
<b>Figura 95.</b> Tecnología del ensayo 8 .....	108
<b>Figura 96.</b> Geometría del ensayo 9 .....	108
<b>Figura 97.</b> Tecnología del ensayo 9 .....	108
<b>Figura 98.</b> Primer punto de medición de rugosidad .....	109
<b>Figura 99.</b> Segundo punto de medición de rugosidad .....	109
<b>Figura 100.</b> Tercer punto de medición de rugosidad .....	109
<b>Figura 101.</b> Matriz de confusión Vc, fn y ap - AA 6061 T6.....	110
<b>Figura 102.</b> Matriz de confusión Vc y fn - AA 6061 T6 .....	110
<b>Figura 103.</b> Matriz de confusión Vc y ap - AA 6061 T6.....	110
<b>Figura 104.</b> Matriz de confusión fn y ap - AA 6061 T6 .....	111
<b>Figura 105.</b> Matriz de confusión Vc, fn y ap - AA 7075 T6.....	111
<b>Figura 106.</b> Matriz de confusión Vc y fn - AA 7075 T6 .....	111
<b>Figura 107.</b> Matriz de confusión Vc y ap - AA 7075 T6.....	112
<b>Figura 108.</b> Matriz de confusión fn y ap - AA 7075 T6 .....	112
<b>Figura 109.</b> Matriz de confusión Vc, fn y ap - análisis conjunto.....	112
<b>Figura 110.</b> Matriz de confusión fn y ap - análisis conjunto.....	113
<b>Figura 111.</b> Matriz de confusión Vc y ap - análisis conjunto .....	113
<b>Figura 112.</b> Matriz de confusión Vc y fn - análisis conjunto.....	113

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> Diámetros de mecanizado .....	9
<b>Tabla 2.</b> Operacionalización de variables dependientes.....	55
<b>Tabla 3.</b> Operacionalización de variables independientes .....	56
<b>Tabla 4.</b> Factores y niveles .....	57
<b>Tabla 5.</b> Arreglo ortogonal de parámetros de corte.....	57
<b>Tabla 6.</b> Resultados de mecanizado AA 6061 T6. ....	58
<b>Tabla 7.</b> Resultados de mecanizado AA 7075 T6. ....	58
<b>Tabla 8.</b> Presentación de resultados del proceso de mecanizado .....	59
<b>Tabla 9.</b> Tiempos de ensayos .....	60
<b>Tabla 10.</b> Índices de tiempo de mecanizado .....	61
<b>Tabla 11.</b> Costo de consumo energético.....	88
<b>Tabla 12.</b> Costo de materiales .....	89
<b>Tabla 13.</b> Costo directo .....	90
<b>Tabla 14.</b> Costo indirecto .....	90

## ÍNDICE DE ANEXOS

<b>Anexo 1.</b> Flujograma de la metodología 1 de 3 .....	102
<b>Anexo 2.</b> Flujograma de la metodología 2 de 3 .....	102
<b>Anexo 3.</b> Flujograma de la metodología 3 de 3 .....	102
<b>Anexo 4.</b> Inserto DCGX 11T304 – AL H10 VCD .....	102
<b>Anexo 5.</b> Inserto DCGX 11T304 – AL H10 PCD .....	102
<b>Anexo 6.</b> Porta inserto SDJCR 2020 K11 .....	102
<b>Anexo 7.</b> Inserto DNMG 150404 – HM NC3020 .....	102
<b>Anexo 8.</b> Porta inserto MDJNR 2020K 1504 .....	102
<b>Anexo 9.</b> Eje para mecanizar probetas AA 6061 T6 .....	102
<b>Anexo 10.</b> Eje para mecanizar probetas AA 6061 T6 .....	102
<b>Anexo 11.</b> Dimensiones probeta 1 .....	102
<b>Anexo 12.</b> Dimensiones probeta 2 .....	102
<b>Anexo 13.</b> Dimensiones probeta 3 .....	102
<b>Anexo 14.</b> Dimensiones probeta 4 .....	102
<b>Anexo 15.</b> Dimensiones probeta 5 .....	102
<b>Anexo 16.</b> Dimensiones probeta 6 .....	102
<b>Anexo 17.</b> Dimensiones probeta 7 .....	103
<b>Anexo 18.</b> Dimensiones probeta 8 .....	103
<b>Anexo 19.</b> Dimensiones probeta 9 .....	103
<b>Anexo 20.</b> Parámetros de mecanizado en EasyCycle Turn .....	103
<b>Anexo 21.</b> Puntos de censo de rugosidad en la probeta .....	109
<b>Anexo 22.</b> Matriz de confusión de la arquitectura neuronal .....	110

## NOMENCLATURA

Símbolo	Descripción	Unidades
$V_c$	<i>Velocidad de corte</i>	$\frac{m}{\min}$
$f_n$	<i>Avance por revolución</i>	$\frac{mm}{rev}$
$a_p$	<i>Profundidad</i>	$mm$
$Ra$	<i>Rugosidad</i>	$\mu m$
$Du$	<i>Índice de Dunn</i>	-
$ARI$	<i>Índice de rand ajustado</i>	-
$AMI$	<i>Información mutua ajustada</i>	-
$NMI$	<i>Información mutua normalizada</i>	-
<b>Subíndices</b>		
$n_i$	<i>Cantidad de elementos en el grupo i</i>	-
$n_j$	<i>Cantidad de elementos en el grupo j</i>	-
$n_{ij}$	<i>Cantidad de elementos que pertenecen al grupo i y la clase j</i>	-
$c_i$	<i>Conjunto i</i>	-
$c_j$	<i>Conjunto j</i>	-
$d_{ij}$	<i>Distancia entre el punto i y j</i>	-
$d_m(i, j)$	<i>Distancia Mahalanobis entre el punto i y j</i>	-
$\max_{1 \leq k \leq n} diam(c_k)$	<i>Distancia máxima entre los centroides de cada grupo</i>	-
$\min_{x \in c_i, y \in c_j} (c_i, c_j)$	<i>Función de disimilitud entre clústeres</i>	-

## INTRODUCCIÓN

La presente investigación determina un análisis espontáneo basado en la metodología de aprendizaje no supervisado, debido a que permite reconocer patrones en función de las variables independientes, utilizando Clustering y Reglas de asociación para identificar el mejor algoritmo que se adapte al requerimiento de la investigación [1].

Se crea un modelo de datos aplicando teoría de elementos de forma (corte periférico e índice de forma geométrica), considerando parámetros dimensionales y tecnológicos para el procedimiento. Partiendo de un proceso de manufactura y mediante la inteligencia artificial se obtendrá el caso de estudio para el análisis del prototipo mecanizado. Su ejecución se aplicará en tecnología por CNC [2].

El Clustering lo que hace es el reconocimiento de patrones mediante agrupamiento, comúnmente llamado análisis de conglomerado, explorando modelos por particionamiento y jerarquías, empleando la noción de similitud o disimilitud entre las características que van a ser agrupadas [3].

En las investigaciones de Biabiany [4] y Kumar [5], concluyen que la determinación de la cantidad de los grupos es la especificación que se debe de considerar en la etapa inicial, para agrupar cierto número de elementos en grupos afines, separados por una distancia; la cual debe de cumplir propiedades como la no negatividad, reflexividad, simetría, densidad triangular e identidad de los indiscernibles. Para que una distancia sea métrica debe de cumplir con todas las propiedades, sin embargo, para que una distancia sea similar o disimilar debe de cumplir las tres primeras propiedades.

Algunos métodos para la medición de las distancias métrica son la distancia Euclidea, Mahalanobis, Manhattan, Chebyshev y Minkowski. Sin embargo, para medidas de similitud se podrá analizar por método de Kulezynsky, Jaccard, Sokal y Michener, Andersoberg, Rogers y Tanimoto, Sneath y Sokal, Pearson, Yuke o Coseno de Salton, que podrán ser calculadas mediante el programa “RStudio” [6].

## **PLANTEAMIENTO DEL PROBLEMA**

En la última década la industria de la manufactura ha desarrollado varias propuestas para la optimización de la calidad en la integridad superficial, entre las opciones poco desarrolladas está el Machine Learning.

Este proyecto tiene como objetivo mejorar la presentación exterior de productos prismáticos circulares a través de nueve ensayos en aleaciones AA 6061 T6 y AA 7075 T6 mediante la manipulación de parámetros de corte en mecanizado CNC.

Con métodos estadísticos a través de redes neuronales se analizará el resultado de dieciocho ensayos, variando la selección del tipo de herramienta, avance y profundidad de mecanizado.

## **FORMULACIÓN DEL PROBLEMA**

¿Cómo influye la aplicación de redes neuronales en operaciones industriales de manufactura para productos prismáticos circulares en materiales metálicos no ferrosos obtenidos en maquinaria torno CNC de marca EMCO modelo E200, utilizado en la Universidad Politécnica Salesiana, en los laboratorios de Tecnología con arranque de viruta?



## **OBJETO DE ESTUDIO**

Proceso de mecanizado para obtener mejora en la calidad superficial, mediante la selección del tipo de herramienta, avance y profundidad de corte y análisis de datos con la utilización de Machine Learning.

## **JUSTIFICACIÓN DE LA INVESTIGACIÓN**

Debido a los bajos índices superficiales ocasionados por fallas ubicadas en la superficie de productos como tubería, contenedores y piezas utilizadas en el área estructural, aeroespacial, metalmecánica y aérea, es de fundamental importancia identificar los factores que ocasionan las marcas, por lo que es indispensable implementar la reducción de estos contrastes, manipulando los factores que los originan [7].

La inteligencia artificial siendo un campo muy amplio que tiene varias áreas de aplicaciones, dentro de las principales está el “Machine Learning” o aprendizaje de máquina, procesamiento natural del lenguaje (captura de texto para sistemas de recomendación), sistemas experto (sistemas en base a la lógica difusa), visión por computador (reconocimiento facial), sistemas de reconocimiento de voz, sistemas de planificación y sistemas de robótica; sin embargo, el campo de estudio en esta investigación es el de reconocimiento de patrones [8].

Fernández et al. [9], deducen que la estructuración para el reconocimiento predictivo va a ser el ingreso de datos y resultados de  $n$  ensayos, para la afirmación de un modelo que se ajuste a condiciones preestablecidas para predicciones con un ruido despreciable.

A través de técnicas estadísticas se podrá reconocer un patrón que se vaya repitiendo y que resulte complejo su identificación; las personas pueden revisar una cantidad limitada de datos y en función a la experiencia se puede determinar el detalle del mismo; sin embargo, la automatización de la técnica de reconocimiento ayudara en la revisión de una lista extensa de resultados y con mayor exactitud en la descripción de patrones [10].

Un programa que reconozca un patrón y que describa el proceso, es una herramienta que mejora el control de la calidad. La parte y/o requerimiento principal para la transformación (proceso disruptivo) relacionada profundamente con extensas cantidades de datos (Big data), es la inteligencia artificial a través de algoritmos de procesamiento de patrones o cualidades [11].

## **OBJETIVOS**

### **OBJETIVO GENERAL**

Aplicar redes neuronales en operaciones industriales de manufactura para productos prismáticos circulares en materiales metálicos no ferrosos obtenidos en maquinaria torno CNC

### **OBJETIVOS ESPECÍFICOS**

Definir el Clustering, correlación de variables, reglas de asociación, dependencias de funciones y validación de resultados, que se aplicara en el análisis del algoritmo de estudio de la integridad superficial.

Determinar un algoritmo de estimación de la calidad superficial, que agrupe un sistema de aprendizaje no supervisado, con un estudio exploratorio y descriptivo, basado en la experimentación de la variación de material del producto, geometría de la herramienta y volumen de material removido en función del tiempo.

Analizar e interpretar los resultados de la integridad superficial del producto prismático circular obtenida en torno CNC, para identificar parámetros de manufactura óptimos en el proceso.

### **Hipótesis de la investigación**

En el desarrollo de los algoritmos de agrupamiento e informática neuronal para predicción y categorización de instancias en materiales no ferrosos, se optimizará la obtención de la integridad superficial analizando el tiempo de mecanizado y la cantidad de caudal de material removido.

Para verificar el cumplimiento de la hipótesis se formula los marcadores de afirmación o negación de la investigación.

### **Hipótesis nula (Ho)**

La calidad superficial no es influenciada por las condiciones del mecanizado.

### **Hipótesis alternativa. (Hi)**

La calidad superficial es influenciada por las condiciones del mecanizado.

### **Alcance**

El alcance que tiene esta investigación involucra dos secciones para analizar, el primero es la correlación que existe entre las variables en el proceso de mecanizado de ensayos y el segundo es el análisis de regresión o clasificación en referencia a la calidad superficial. Con este estudio se establecerá los parámetros óptimos para obtener rugosidad de alta calidad y menor caudal de material evacuado.

### **Descripción de la estructura de los capítulos del proyecto de investigación**

El desarrollo de la investigación se hizo en función de los objetivos específicos planteados en la investigación.

En el capítulo uno se realiza la recopilación de los temas que involucra los parámetros de mecanizado en el torno, análisis de conglomerados con las medidas de validación interna y externa, correlación de variables, mapas de calor y parámetros para la formulación del análisis neuronal.

En el capítulo dos se simula la manufactura del Torno CNC y se formula en función a cada una de las aleaciones y un esquema con análisis compartido de las dos aleaciones del análisis de clustering, rendimiento de agrupaciones, estructuración de la arquitectura de la red neuronal y evaluación de predicciones.

En el capítulo tres se ejecuta la programación, tomando los resultados del mecanizado en torno en CNC como Dataset para el análisis mencionado en el capítulo dos, esencialmente el análisis se centra en la comparación de los resultados de los dos materiales mecanizados.

# **CAPÍTULO 1**

## **MARCO CONTEXTUAL Y TEÓRICO SOBRE EL ANÁLISIS DE LA FORMULACIÓN DE ALGORITMOS**

### **1.1 Introducción**

El principal objetivo del reconocimiento de patrones es descubrir el comportamiento de los procesos, seleccionando las fisonomías personales de cada instancia que permitan categorizarlos de la mejor manera [12].

### **1.2 Marco teórico de la investigación**

#### **1.2.1 Antecedentes de la investigación**

El inicio de la calidad comenzó desde la revolución industrial con la existencia de las máquinas y sus procesos de forma muy manual, sin embargo, con la inclusión de procesos estadísticos (orientados en la industria automotriz, alimenticia y de producción) se descubrió un funcionamiento óptimo, sobre todo en la segunda guerra mundial, ejecutando y permitiendo extrapolación en otras regiones u otros sistemas de producción [13].

En la década de 1930 nace el control estadístico, siendo una estrategia utilizada hasta la actualidad en diversos sistemas (apertura para el aseguramiento de la calidad por las normas ISO), en 1980 nace el KAISEN compartiendo el concepto de la calidad total y en el 2000 se presenta la idea de la cadena del valor total; no obstante, el estudio de la presente investigación se centra en la calidad para la industria 4.0 [14].

#### **1.2.2 Prologo**

##### **1.2.2.1 Parámetros de mecanizado**

###### **1.2.2.1.1 Velocidad de corte ( $V_c$ )**

Es la rapidez entre la superficie del material a procesar y el inserto de la herramienta, representado en la Figura 1; en empresas de producción en serie la principal meta es minimizar el costo del producto y maximizar la producción de unidades. En la investigación de Jarrin [15], indica que en la experimentación de los ensayos la condición optima es 420 m/min.



**Figura 1.** Velocidad de corte

#### 1.2.2.1.2 Volumen de material removido

Es el material residual de la operación de torneado. En la investigación se establece un volumen constante; tomando de referencia los diámetros del primer ensayo y longitud de mecanizado de 100 mm, se determina la obtención de  $22.2 \text{ cm}^3$ .

$$\begin{cases} \phi_i = 60.00 \text{ mm} \\ \phi_f = 57.60 \text{ mm} \\ l = 100.00 \text{ mm} \end{cases} \rightarrow \begin{cases} \phi_i = 6.00 \text{ cm} \\ \phi_f = 5.76 \text{ cm} \\ l = 10.00 \text{ cm} \end{cases}$$

$$A_{Total} = A\phi_i - A\phi_f$$

$$A_{Total} = \frac{\pi(\phi_i)^2}{4} - \frac{\pi(\phi_f)^2}{4}$$

$$A_{Total} = 28.2743 \text{ cm}^2 - 26.0576 \text{ cm}^2 = 2.22 \text{ cm}^2$$

$$V = l \cdot A_{Total} = 10 \text{ cm} \cdot 2.22 \text{ cm}^2 = 22.2 \text{ cm}^3$$

En la Tabla 1 se presentan los diámetros para mecanizar en los ensayos del estudio.

<b>Tabla 1.</b> Diámetros de mecanizado	
<b>Diámetro inicial</b>	<b>Diámetro final</b>
<b>[mm]</b>	<b>[mm]</b>
60.00	57.60
57.60	55.10
55.10	52.47
52.47	49.71
49.71	46.78
46.78	43.66
43.66	40.30
40.30	36.63
36.63	32.56

#### 1.2.2.1.3 Profundidad ( $a_p$ )

Es la hondura que recorre la herramienta en el material, a medida que el torno hace girar la pieza a mecanizar; se puede evidenciar en la Figura 2. En la experimentación se utilizará profundidades de 0.3, 0.6 y 1.2 mm [16].




Figura 2. Profundidad

#### 1.2.2.1.4 Avance ( $f_n$ )

Es la distancia que avanza el inserto de corte sobre la superficie a mecanizar en un periodo de tiempo, representado en la Figura 3. Para la experimentación de estudio se tomó valores de 0.1, 0.2 y 0.3 mm/rev para evitar la ruptura de la herramienta ocasionando calidad superficial deficiente [17].





Figura 3. Avance de la herramienta

#### 1.2.2.1.5. Caudal de material removido

Es el volumen de material desalojado en el tiempo de mecanizado de cada probeta, representada en la Figura 4. La información servirá para analizar la relación que existe entre rugosidad y la cantidad de viruta producida por proceso [18].






**Figura 4.** Caudal de material removido

#### 1.2.2.1.6 Rugosidad


Es la micro geometría (crestas y valles) presente en la superficie de las probetas mecanizadas como se puede evidenciar en la Figura 5, dependiendo de las variables de mecanizado la integridad superficial tendrá un porcentaje de irregularidades [19].



**Figura 5.** Rugosidad de una superficie

#### 1.2.2.1.7 Tiempo de mecanizado

Es el tiempo medido en la operación de manufactura de los ensayos del proyecto [20], para tabular la variable en la investigación, se censó el tiempo real de mecanizado y el tiempo simulado como se muestra en la Figura 6.



**Figura 6.** Tiempo de mecanizado

#### **1.2.2.2 Análisis de reconocimiento de patrones**

En las investigaciones de Ning Sung [21], Gao [22] y Caggiano [23], concluyen que en la industria es muy importante el censo de los datos, porque de esta manera permite de una forma muy eficiente el análisis del modelo de comportamiento en la información de la producción.

##### **1.2.2.2.1 Control de calidad basado en reconocimiento de patrones**

Es un proceso de reconocimiento de modelos que representa el comportamiento de los datos, exhibiendo pautas para el control de manera automatizada, mediante técnicas estadísticas, siendo el requisito fundamental para su aplicación el internet de las cosas (datos censados procedentes de máquinas o procesos conectados al internet) [24].

La cronología industrial relata los inicios desde la implementación del vapor, producción en serie, automatización de procesos y los sistemas controlados de manera automática (los procesos automáticos basados en datos correspondientes a la factoría del futuro se analizarán en la investigación) [25].

##### **1.2.2.2.2 Conjunto de datos**

El Dataset, información estructurada, donde las filas indican una nueva instancia (observación o medición) y las columnas un atributo o variable a trabajar y que generalmente contienen metadatos (información descriptiva del recurso) [26].

Datos quemados, es la información censada que no puede ser modificada (base de datos que se cerró en un cierto tiempo o espacio); de forma genérica y anónima la información suele ser donada a diferentes repositorios (colecciones de datos) para ser refutada o validada la investigación, por ejemplo, UCI (Machine Learning Repository, datos.gob.es, DATA.GOV, KDNuggets TM, Gapminder o mldata.org) [27].

Datos dinámicos, es la información que se está procesando en el instante o momento presente y a través de interface de aplicación o de programación se pueda recuperar para estudiar [28].

#### **1.2.2.2.3 Formato**

Para el procesamiento de los datos es de vital importancia el formato con el cual se procesará la información, existen formatos con mayor y menor libertad de información, la idea es la liberación de información en formatos que puedan ser procesados (información que pueda ser en un futuro examinada por cualquier lenguaje de programación o por cualquier persona en cualquier sistema operativo) [29].

#### **1.2.2.2.4 Knowledge Discovery in Databases**

Descubrimiento de información para describir y determinar patrones en grandes conjuntos de datos, centrando el análisis en la generación de modelos y control de la información [30].

#### **1.2.2.2.5 Paradigma de la minería de datos**

En las investigaciones de Xiao [31] y Baker [32] concluyen que en la minería de datos existen dos paradigmas que son la verificación y el descubrimiento. En “La verificación” se tiene presente el test o contrastes de hipótesis, la bondad de ajuste y análisis de la varianza o ANOVA, que sirven para el control de procesos y lo que se va a desarrollar “El descubrimiento” que asiste en la descripción de los datos que encontramos ciertos patrones imperceptibles, con herramientas como la clasificación, regresión o clustering.

#### **1.2.2.3 Paradigmas del Machine Learning**

En las investigaciones de Escobar [33] y Gao [34] describen que la inteligencia artificial tiene un alcance muy amplio, y varias aplicaciones; dentro de las principales ramas está el aprendizaje supervisado, no supervisado y por reforzamiento, captura de texto para sistemas de recomendación, sistemas basados en lógica difusa, sistema con un conjunto de reglas que brindan experiencia al análisis, reconocimiento facial y fonético, sistemas de planificación y robótica.

En las investigaciones de Farinella [35], Ajagekar [36] y Janarthanan [37] determinan la diferencia entre las dos formas del aprendizaje asistido por computador. La manera tradicional se caracteriza por el ingreso de la información (datos y condicionales) para generar el programa y de forma automática la computadora presente un resultado. Y el aprendizaje por computador que se caracteriza por el ingreso de la información y

resultados para que la computadora reconozca el patrón y genere el programa para ser analizado por un sistema experto.

Dentro de los paradigmas de aprendizaje clásico se tiene el aprendizaje supervisado, no supervisado y por refuerzo. El estudio por refuerzo es un aprendizaje en el cual se le va castigando o premiando al sistema en función de las actividades que se va ejecutando. Por ejemplo, la educación de las personas en el transcurso de su crecimiento hasta la edad adulta [38].

#### **1.2.2.3.1 El aprendizaje supervisado**

Parte de variables dependientes (variable exógena) e independientes, para generar el resultado de la predicción mediante la estructura de clasificación y regresión que permita la toma de decisiones [39]. Para la predicción de variables dependientes se tiene estructuras de clasificación (agrupación de variables cualitativa nominal u ordinal, o cuantitativa discreta) y regresión (predicción de una variable cuantitativa continua) [40].

#### **1.2.2.3.2 El aprendizaje no supervisado**

Es el análisis que permite el reconocimiento de patrones en datos censados; en función de la experiencia (variable independiente) se encuentra la variable exógena con técnicas de algoritmos de Clustering y Reglas de Asociación [41].

#### **1.2.2.3.3 Clustering**

Es una técnica estadística del control moderno que se utiliza para el reconocimiento y obtención de modelos mediante análisis de conglomerados, algoritmos de particionamiento K-mean o PAM, agrupación jerárquica divisiva y modelos basados en la mezcla de los anteriores [42].

#### **1.2.2.4 Distancia**

##### **1.2.2.4.1 Distancia Euclidiana**

Es la distancia o línea recta que une dos puntos, para que una distancia sea considerada como tal, tiene que cumplir las siguientes propiedades:

1. No negatividad, la distancia entre el punto “i” y “j” tiene que ser mayor e igual que cero.

$$d_{ij} \geq 0 \quad [1]$$

2. Reflexividad, la distancia entre el punto “i” e “i” va a ser cero, es decir entre un mismo elemento.

$$d_{ii} = 0 \quad [2]$$

3. Simetría, la distancia entre los puntos “i” y “j” es igual a la distancia entre los puntos “j” e “i”.

$$d_{ij} = d_{ji} \quad [3]$$


4. Desigualdad triangular, la distancia entre los puntos “i” y “j” tiene que ser menor e igual que la sumatoria de la distancia entre los puntos “i” y “k” más la distancia entre los puntos “j” y “k”.

$$d_{ij} \leq d_{ik} + d_{jk} \quad [4]$$

5. Identidad de los indiscernibles, describe que la distancia entre los puntos “i” y “j” es igual a cero siempre y cuando si las coordenadas de “i” sean igual a “j”.

$$d_{ij} = 0 \Leftrightarrow i = j \quad [5]$$

A continuación, se presenta la gráfica de la distancia euclidiana, referenciando los puntos “i” y “j” en el plano cartesiano.



**Figura 7.** Distancia Euclidiana

En la Figura 7 se puede denotar la distancia “ $d$ ”, sin embargo, la formulación analítica se presentará en la Ecuación 6.

$$d_{(p_i, p_j)} = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad [6]$$

#### 1.2.2.4.2 Distancia y similitud

En las investigaciones de Cai [43] y Baazaoui [44] concluyen que para una distancia ser métrica debe de cumplir con las cinco propiedades descritas en la sección anterior, no obstante, para que sea una medida de disimilitud deberá de cumplir únicamente con las propiedades de no negatividad, reflexividad y simetría.

#### 1.2.2.4.3 Distancia Mahalanobis

En las investigaciones de Çakmakçı [45] y Qi [46] definen que es el cálculo de la distancia entre dos puntos “ $i$ ” y “ $j$ ”, tomando en consideración la correlación entre las variables asignadas; frecuentemente utilizado en el análisis de similitud de los productos para la venta.

$$d_m(i, j) = \sqrt{(\vec{i} - \vec{j})^T \sum^{-1} (\vec{i} - \vec{j})} \quad [7]$$

#### 1.2.2.4.4 Distancia Manhattan

En las investigaciones de Zang [47] y Blackburn [48] indican que la distancia entre dos puntos no necesariamente es una línea recta, es decir, es la suma de las diferencias absolutas (bordes de bloques que rodean la ruta) o tomando de referencia la forma de

un triángulo rectángulo, la distancia vendrá a ser la suma de los catetos; frecuentemente se utiliza en el área civil en el levantamiento de distancias en una carretera, como se presenta en la Figura 8.



**Figura 8.** Distancia de Manhattan

#### 1.2.2.4.5 Distancia Chebyshev

Es la distancia entre dos vectores definida en un espacio y de longitud mayor a sus diferencias, frecuentemente utilizado en el área de almacenaje para evitar muda de movimientos [49].

$$D(i, j) = \max_a |i_a - j_a| \quad [8]$$

#### 1.2.2.4.6 Distancia Minkowski

En las investigaciones de Choe [50] y Huang [51] indican que es una medida utilizada en un plano de n dimensiones (vector representado como distancia) cumpliendo requisitos de la desigualdad triangular, factor escalar y vector cero.


#### 1.2.2.5 Escalamiento multidimensional

En las investigaciones de Dzemyda [52], Sato [53] y Machado [54] definen como una técnica utilizada para modelos cuantitativos, para control de producción. Cuando un conjunto de datos del proceso industrial tiene más de tres dimensiones, se debe reducir la cantidad de dimensiones (no se reduce la cantidad de datos, sino la cantidad de

variables); es decir se tendrá una cantidad de variables que permita la representación gráfica y se lo hará a través de una métrica de distancia.

#### 1.2.2.6 Algoritmo K-means

Crea agrupaciones y divisiones con las variables independientes de una colección de datos. El análisis toma el centroide y la medición de cada instancia, confluyendo cuando la media del punto medio no cambia de posición, ideal para ser aplicado en redes multinivel, redes dinámicas, redes dinámicas multinivel y meta-redes; en la Figura 9 se puede observar el agrupamiento [55].




**Figura 9.** Algoritmo K-means

#### 1.2.2.7 Algoritmo Jerárquico


Es un algoritmo voraz y muy rápido por lo que es ideal para procesar información con gran cantidad de datos. El análisis toma un conjunto grande de instancias y lo divide en grupos pequeños para crear ramificaciones en forma de árbol, cada rama es un grupo generado y se puede evidenciar en la Figura 10 [56].





**Figura 10.** Algoritmo DHC

En la Figura 11 se presentan las dos técnicas de análisis que se clasifica el algoritmo:



**Figura 11.** Clasificación del algoritmo Jerárquico

### 1.2.2.7.1 Métricas de Agrupamiento jerárquico

#### 1.2.2.7.1.1 Agrupación de enlace simple (single-link)

Se utiliza el algoritmo “Nearest Point Algorithm”, para minimizar la distancia inter clúster y maximizar la distancia extra clúster, presentando grupos bien compactados y separados, garantizando la coerción dentro de los grupos [57].

$$d(c_i, c_j) = \min(d(x_i, x_j)) ; \{ \forall x_i \in c_i, \forall x_j \in c_j \} \quad [9]$$

#### 1.2.2.7.1.2 Agrupación de enlace completo (complete-link)

Se utiliza el “Farthest point algorithm” o “Algoritmo de Voor Hees”, lo que hace es maximizar la distancia intra clúster, garantizando que la distancia entre dos diferentes clústeres sea la máxima [58].

$$d(c_i, c_j) = \max(d(x_i, x_j)) ; \{ \forall x_i \in c_i, \forall x_j \in c_j \} \quad [10]$$


#### 1.2.2.7.1.3 Agrupación de enlace promedio (average-link)

Es una mezcla de los dos análisis utilizados anteriormente, generalmente suele presentar los mejores resultados, dependiendo la configuración de la información. Promedia entre la minimización y maximización de la distancia inter clúster [59].

$$d(c_i, c_j) = \frac{1}{|c_i||c_j|} \sum_{x_i \in c_i, x_j \in c_j} d(x_i, x_j) \quad [11]$$

#### 1.2.2.8 Algoritmo de Elbow

En las investigaciones de Ali [60] y Afzal [61] describen como método iterativo que permite determinar y verificar la distancia inter clúster, para posteriormente establecer un número ideal de grupos con los que se debería trabajar; la Figura 12 describe la curva de funcion, mientras más tiende a la derecha el número de clústeres mayor es la existencia de grupos artificiales.



**Figura 12.** Algoritmo de Elbow

### 1.2.2.9 Métodos de validación interna

Atribuye el nombre porque no toma ninguna observación de referencia para comparar en el estudio; utilizando el principio de las métricas, se determina que la distancia entre las instancias internas de cada agrupación sea la mínima y la distancia entre cada grupo sea la máxima [62].

#### 1.2.2.9.1 Índice de Dunn

Park et al. [63], concluyen que es un valor numérico subjetivo no normalizado definido entre cero e infinito, siendo cero el peor y la tendencia al infinito la mejor calidad de agrupamiento; es el índice adecuado cuando no se tiene métrica de supervisión, pero se desea explorar. Por ejemplo, en la producción de piezas que luego de emplear un proceso de agrupamiento o clustering se reestructura en función de los atributos y mejora la calidad del producto.

$$D_{Dunn} = \min_{1 \leq i \leq n} \left\{ \min_{1 \leq j \leq n, i \neq j} \left( \frac{\min_{x \in C_i, y \in C_j} (c_i, c_j)}{\max_{1 \leq k \leq n} \text{diam}(c_k)} \right) \right\} \quad [12]$$


Donde:

$\min_{x \in c_i, y \in c_j} (c_i, c_j)$  es la función de disimilitud entre los clústeres  $c_i$  y  $c_j$ .

$\max_{1 \leq k \leq n} diam(c_k)$  es la distancia entre los centroides de cada grupo deseando ser la más grande posible.

#### 1.2.2.9.2 Coeficiente de Silueta

En las investigaciones de Zafari [64] y Quan [65], concluyen que es un valor numérico normalizado definido entre cero y uno (grupos convexos, bien separados y con densidad alta), similar al Índice de Dunn, adicionalmente presenta un resultado grafico (Figura 13), con los grupos formados denotando el tamaño y la densidad de las instancias.



**Figura 13.** Coeficiente de Silueta

El coeficiente de silueta  $S(i)$  se obtendrá mediante el análisis de las siguientes condiciones:

$$S(i) = \begin{cases} 1 - \frac{a(i)}{b(i)} & ; \text{ si } a(i) < b(i) \\ 0 & ; \text{ si } a(i) = b(i) \\ \frac{a(i)}{b(i)} - 1 & ; \text{ si } a(i) > b(i) \end{cases}$$

Siendo:

$i$  es el objeto de referencia en el Data Set.

$a(i)$  es el resultado de clúster calculado se mide la distancia entre un objeto y todos los objetos del mismo grupo.

$b(i)$  es la medición del clúster del grupo analizado y los grupos adyacentes más cercanos al mismo.

El valor del coeficiente de silueta promedio se obtiene mediante la Ecuación 12.

$$S(i) = \frac{b(i) - a(i)}{\max[a(i), b(i)]} \quad [13]$$

#### 1.2.2.10 Métodos de validación externa

En las investigaciones de Chang [66] y Bongers et al. [67], indican que es una medida de cotejo del resultado del grupo formado en relación a una asociación ideal (excelente clasificación).

##### 1.2.2.10.1 ARI, Adjusted Rand Index

Kayaalp [68], concluye que es un índice numeral normalizado entre cero y uno (mayor sea el resultado mejor será la semejanza de la agrupación), compara una asociación referencial (ground truth) con el resultado de la clasificación desarrollada.

$$ARI = \frac{RI - E[RI]}{\max(RI) - E[RI]} \quad [14]$$

Siendo:

$[RI]$  es la recuperación de la información.

$E[RI]$  es la esperanza de la recuperación de la información.

$\max(RI)$  es la máxima recuperación de la información.

El índice aleatorio  $RI$  sin ajuste (valor de recuperación de la información) se podrá expresar mediante la Ecuación 15.

$$RI = \frac{a+b}{A_2^n} \quad [15]$$

Siendo:

$A$  el ground truth

$B$  las clases predichas por la clasificación.

$a$  es el número de pares de elementos en el mismo conjunto en  $A$  y  $B$ .

$b$  es el número de pares de elementos en diferentes conjuntos en  $A$  y  $B$ .

$A_2^n$  es el número total combinaciones posibles.

#### 1.2.2.10.2 AMI, Adjusted Mutual Information

Medida de validación normalizada entre uno negativo y uno, siendo mala y buena relación de información mutua respectivamente [69].

$$AMI(A, B) = \frac{MI - E[MI]}{\max(H(A), H(B)) - E[MI]} = \frac{MI - E[MI]}{\sqrt{H(A)H(B)} - E[MI]} \quad [16]$$

Siendo:

$MI$  es la información mutua

$E[MI]$  es la esperanza de la información mutua

$\max(H(A), H(B)) - E[MI]$  es el máximo valor entre la entropía de A y B menos la esperanza de la información mutua.

### 1.2.2.10.3 NMI, Normalized Mutual Information

Es un índice normalizado entre uno negativo y uno, que analiza la meta información y el factor de incertidumbre (entropía) que existe dentro de los elementos, se trata de hallar el grado de desorden que hay en los conjuntos. A mayor entropía menor coincidencia de conjunto y viceversa [70].

Se puede calcular la función de coincidencia entre parámetros (MI) a través de la Ecuación 17.

$$MI(A, B) = H(A) + H(B) - H(A, B) = \sum_{i=1}^c \sum_{j=1}^k \frac{n_{ij}}{n} \log \frac{n_{ij}n}{n_i n_j} \quad [17]$$

Siendo:

$H(A)$  Entropía de la variable A

$H(B)$  Entropía de la variable B

$H(A, B)$  Entropía conjunta entre agrupamientos

En la Ecuación 18 se normaliza el “Mutual Information –  $MI(A, B)$ ” dividiendo con la raíz cuadrada de la desviación estándar para hallar la información mutua normalizada.

$$NMI(A, B) = \frac{MI(A, B)}{\sqrt{H(A)H(B)}} = \frac{\sum_{i=1}^c \sum_{j=1}^k \frac{n_{ij}}{n} \log \frac{n_{ij}n}{n_i n_j}}{\sqrt{\left( \sum_{i=1}^c \frac{-n_i}{n} \log \frac{n_i}{n} \right) \left( \sum_{j=1}^k \frac{-n_j}{n} \log \frac{n_j}{n} \right)}} \quad [18]$$

Siendo:

$n$  la cantidad de elementos.

$n_i$  la cantidad de elementos que pertenecen al grupo  $i$ .

$n_j$  la cantidad de elementos que pertenecen al grupo  $j$ .

$n_{ij}$  la cantidad de elementos que pertenecen al grupo  $i$  y la clase  $j$ .

### 1.2.3 Costo de mecanizado

El costo total comprende todo gasto generado para la elaboración del ensayo en diferentes entornos.

$$C_T = C_e + C_o + C_i \quad [19]$$

Siendo:

$C_T$  Costo total

$C_e$  Costo de consumo energético

$C_o$  Costo general

$C_i$  Costo del inserto de corte

#### 1.2.3.1 Costo de consumo de energía $C_e$

Es el precio relacionado con el tiempo de consumo energético en la maquinaria durante el mecanizado del producto.

$$C_e = C_{corte} + C_{n-corte} \quad [20]$$

Siendo:

$C_{corte}$  Costo de la energía

$C_{n-corte}$  Costo en espera de la maquina

Se puede relacionar el consumo de la energía en función de la potencia y eficiencia a través de la Ecuación 21.

$$C_e = \frac{CUE}{(n)(60)(1000)} (t_m) (PC + ER) \quad [21]$$

Siendo:

$CUE$  Costo unitario de la energía (2.80 dólares por cada kWh)

$n$  Eficiencia de la maquina (85%)



*PC* Potencia de corte de la máquina (9307 W - 420 m/min)

*ER* Potencia de espera (1987 W)

*t<sub>m</sub>* Tiempo de mecanizado, se determina para cada experimento.

### 1.2.3.2 Costos generales

Es un costo indirecto que involucra la sumatoria de costos de operación.

$$C_o = C_{op} + C_L + C_m \quad [22]$$

Siendo:

*c<sub>op</sub>* Costo del operador

*c<sub>L</sub>* Costo del sistema de luminaria

*c<sub>m</sub>* Costo de la depreciación de la maquinaria

Donde el costo operativo durante el mecanizado esta descrito en la Ecuación 23.

$$C_{op} = Ct \cdot t_M \cdot O \quad [23]$$

Siendo:

*Ct* Tasa de costo del operador (\$/h)

*t<sub>M</sub>* Tiempo de la maquina (h)

*O* Número de trabajadores

De igual manera para el sistema de la iluminación, puede ser desarrollado mediante la Ecuación 24:

$$C_L = N(P)t_L CUE \quad [24]$$

Siendo:

*N* Numero de luminarias

*P* Potencia de la luminaria [kW]

*CUE* Costo unitario de la energía (2.80 dólares/kWh)

$t_L$  Tiempo de la maquina (h)

El costo de la depreciación de la maquina se determina:

$$C_m = \frac{(\text{costo inicial} - \text{valor del rescate})(\text{tiempo de maquinado})}{\text{vida util}} \quad [25]$$

No obstante, reemplazando los términos de la Ecuación 25, se puede calcular con facilidad en función del tiempo de maquinado de cada proceso.

$$C_m = \frac{(75000 - 50000)(t_m)}{\left(10 \text{ años} \cdot \frac{250 \text{ dias}}{\text{año}} \cdot \frac{8h}{\text{dia}}\right)} \quad [26]$$

#### 1.2.3.3 Costos de la herramienta $C_t$

Es el valor económico que se pueda recuperar en la reventa del inserto luego de ser rectificado tras alcanzar un desgaste de 0.3 mm.

$$C_t = \frac{P_i - P_r}{VH} \cdot t_m \quad [27]$$

Siendo:

$P_i$  Precio inicial

$P_r$  Precio de la reventa

$VH$  Vida útil de la herramienta

$t_m$  Tiempo de mecanizado, se determina para cada experimento.

#### 1.2.4 Multi clasificadores para control de la producción


Es una exploración preventiva de manufactura, que garantiza el descubrimiento de inconvenientes previamente a su acontecimiento, se puede hacer solo con datos [71].

#### **1.2.4.1 Antecedentes**

Alan Turing a mediados de los años treinta creó la primera formulación del comportamiento del cerebro como un modelo informático, W. McCulloch y W. Pitts enunciaron a principios de los años cuarenta el modelo base de una neurona, D. Hebb a finales de los años cuarenta contextualizó psicológicamente la mecánica jerárquica del aprendizaje, Karl Lashley en 1950 descubrió que la información era almacenada en la superficie del cerebro, en 1956 el Congreso de Dartmouth dio apertura al inicio del nacimiento de la inteligencia artificial, Frank Rosenblatt en 1959 desarrolló y construyó el Perceptrón (Simple Neural Machine), B. Widrow y M. E. Hoof en 1960 inventaron y trabajaron con Adaline (Adaptive Linear Element) [72], Karl Steinbeck en 1961 desarrolla la memoria asociativa, Marvin Minsky y Seymour Papert en 1969 presentaron una demostración matemática que concluyó que el perceptrón no resolvía problemas fáciles, Stephen Grossberg y Gail Carpenter en 1970 propusieron el modelo lineal ART (Teoría de la resonancia adaptativa), Paul Werbos en 1974 desarrolló la idea del algoritmo Back propagation, Stephen Grossberg en 1977 a través de la teoría de resonancia adaptada (TRA) simuló la memoria de corto y largo plazo, John Hopfield en 1985 reenfoca el concepto de red neuronal, David Rumelhart y G. Hinton en 1986 redescubrieron el algoritmo “Back Propagation” y McClelland y Rumelhart en 1986 crean un libro que presenta ventajas y desventajas de las redes neuronales artificiales [73].

#### **1.2.4.2 Red neuronal artificial**

Es un sistema bio-inspirado; es un modelo matemático con forma estructural de cerebro que traslada el comportamiento biológico de las neuronas representado en la Figura 14. Presenta una gran dependencia computacional debido a su extensa cantidad de datos, esencialmente por el proceso de entrenamiento, para formar el proceso de sinapsis se unen varias neuronas [74].



**Figura 14.** Neurona artificial

Está estructurado por un núcleo, que gestiona la información receptada, dendritas que reciben impulsos eléctricos y el axioma permite emitir la información receptada y procesada; el funcionamiento comienza con la recepción de la información, procesamiento y emisión de datos analizados [75].


Dentro del sistema se tiene la función de aprendizaje, debe de tener un esquema para que pueda educarse, si permite hacer una predicción con un ruido casi inexistente se denomina inteligente, por ejemplo, el programa Eliza inventado en Massachusetts Institute of Technology, permitía describir lo que estaba pasando el usuario [76].

#### **1.2.4.3 Ventajas**

Puede ser aplicado para varias tareas en diferentes campos por ejemplo en las áreas de la medicina, electricidad, biología entre otras ramas, su aprendizaje es adaptativo, auto organizador, presenta tolerancia a los fallos, permite una conexión entre el hardware y software a tiempo real posibilitando la extrapolación en otros sistemas [77].

#### **1.2.4.4 Modelo de McCulloch & Pitts**

Este sistema toma la presencia de una sola neurona, considera a las variables independientes en el sistema como las entradas (dendritas). Para que exista aprendizaje lo que se debe de calcular son “los pesos” y que aprenda en la función [78].



**Figura 15.** Neurona de McCulloch & Pitts


El modelo representado en la Figura 15 indica que si se multiplica las entradas por los pesos y se suman todos esos valores entonces tiene que ser mayor que una función de nombre “Función de activación”, “Unidad lógica de umbral” o “Unidad de umbral lineal”, lo que indica que a partir del umbral se debe de tomar una decisión [79].

$$MCP_{Modelo} : f = 1 \xrightarrow{\text{Si}} \sum_{i=1}^n x_i w_i > t \quad [28]$$

El modelo está únicamente diseñado para la clasificación, solo permite determinar si la variable dependiente o el resultado es una variable cualitativa nominal (categórica) o variable cuantitativa discreta, pero únicamente permitirá resolver problemas de clasificación binaria (genero de las personas, blanco o negro, sal o azúcar, etc) [80].

#### 1.2.4.5 Perceptrón

Se creo el diseño en 1957, modificó la función de aprendizaje de los modelos lineales sumando un coeficiente  $b$  para ser efectuada en la función de activación, en la Figura 16 se presenta el esquema neuronal de la función [81].



**Figura 16.** Perceptrón

A continuación, se expresará la función considerando las dos condiciones de análisis para el hiperplano.


$$P_{Modelo} : f(x) = \begin{cases} 1 \xrightarrow{Si} \sum_{i=1}^n x_i w_i + b > 0 \\ -1 \xrightarrow{Si} \sum_{i=1}^n x_i w_i + b \leq 0 \end{cases} \quad [29]$$

#### 1.2.4.5.1 Perceptrón simple

Análisis simple que se utiliza con problemas de clasificación entre valores de 0 y 1, es decir una clasificación binomial; permite resolver problemas lineales y modelos no lineales [82].

#### 1.2.4.6 ADALINE: Adaptive Linear Neuron

Es una neurona que analiza el ruido cometido permitiendo actualizar los pesos, representada en la Figura 17. Resuelve problemas de regresión calculando la distancia entre el hiperplano y cada instancia [83].



**Figura 17.** Esquema ADALINE

Fue desarrollado en 1960 para el aprendizaje, utiliza las cantidades de la salida para determinar el ruido en la regresión, estimando que sea lo mínimo.

$$E = \sum_{p=1}^m E^p = \frac{1}{2} \sum_{p=1}^m (d^p - y^p)^2 \quad [30]$$

Siendo

$E$  : Error global

$E^p$  : Error cuadrático por patrón

$d^p - y^p$  : Diferencia entre el valor real y valor estimado

#### 1.2.4.7 Redes Neuronales Artificiales RNA (Hecht - Nielssen)

En el año de 1993 se lanza una estructura lógica que unen más de dos neuronas con una arquitectura formando un grafo y calcula los pesos existentes de cada elemento del proceso, el ciclo de enseñanza se hace unidireccionalmente, de izquierda a derecha se denomina “propagación hacia adelante” y el proceso de regresar desde el valor final hasta los valores de las variables independientes se le conoce con el nombre de “propagación hacia atrás” [84].

##### 1.2.4.7.1 Esquema de una red neuronal

En la Figura 18 se puede evidenciar el esquema que posee tres capas de ensimismamiento, la primera es donde se tienen las variables independientes y recibe información de fuentes externas de la red, las columnas continuas hasta la penúltima son donde se realiza la arquitectura del procedimiento que permite determinar el mejor desarrollo y la última columna es la capa es donde se tienen las variables de dependientes [84].

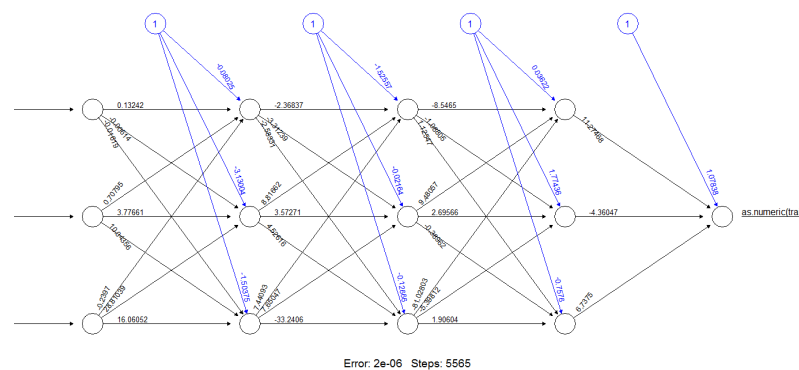
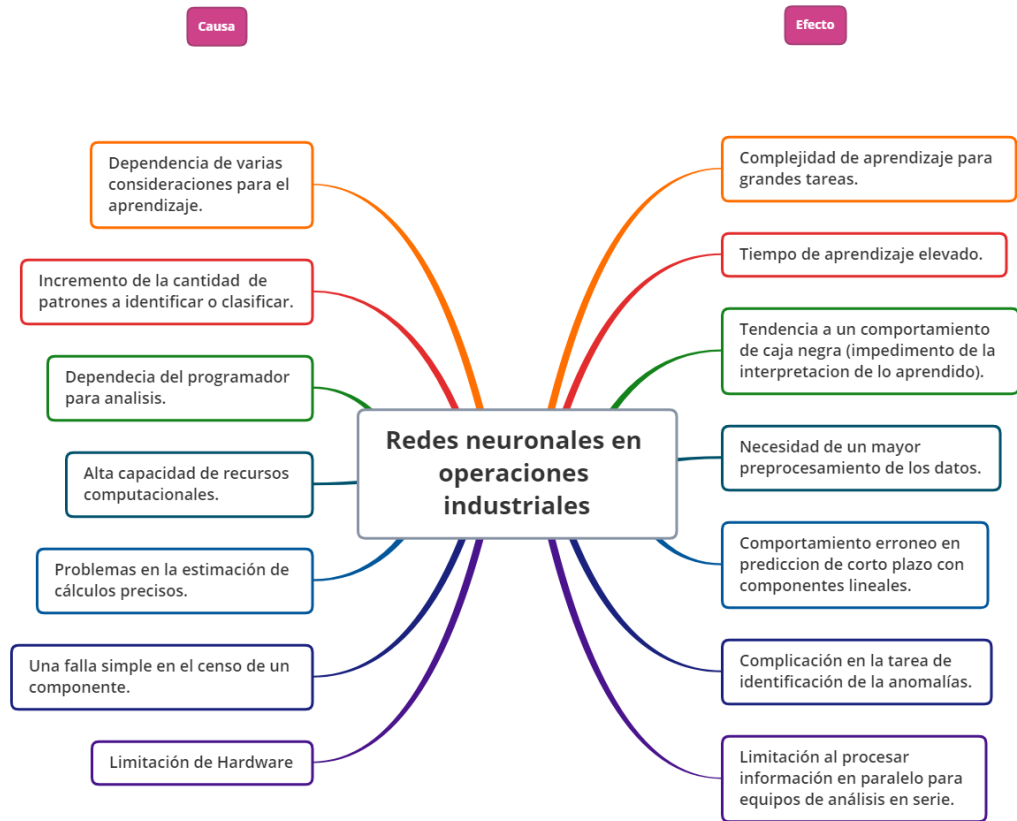


Figura 18. Esquema de una RNA

### 1.3 Fundamentación de la investigación

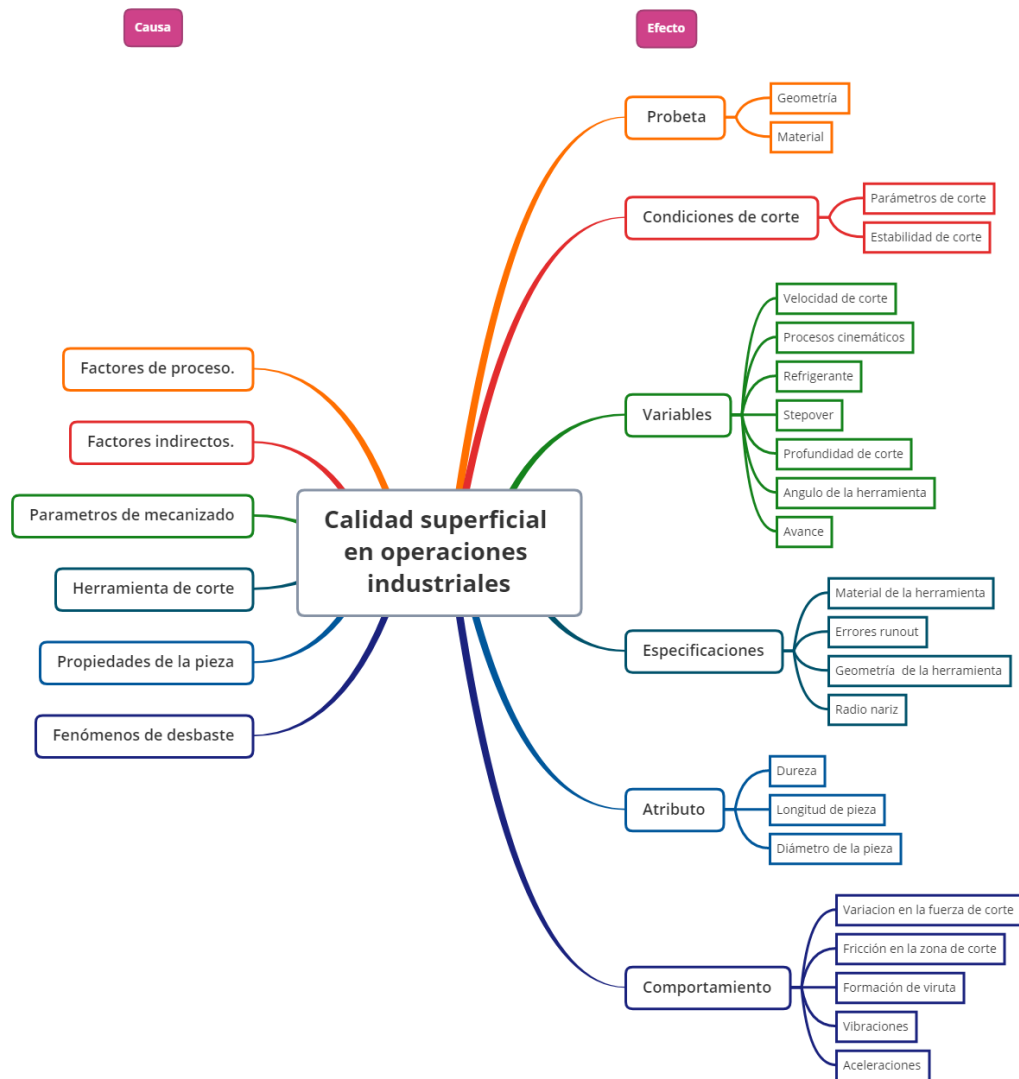
En el árbol de problemas presentado en la Figura 19, se analizan las causas y efectos de la aplicación de ANN en el estudio, concluyendo que al usar el análisis en operaciones industriales se ve delimitado principalmente por la alta capacidad de recursos computacionales y la limitación al procesar información en paralelo con los equipos actuales que trabajan en serie [85].



**Figura 19.** Árbol de problemas “Redes neuronales”

En la Figura 20, se analizan las causas y efectos de la calidad superficial en operaciones industriales; concluyendo que la rugosidad se ve influenciada por variables como la dureza del material, avance del mecanizado, velocidad y profundidad de corte.



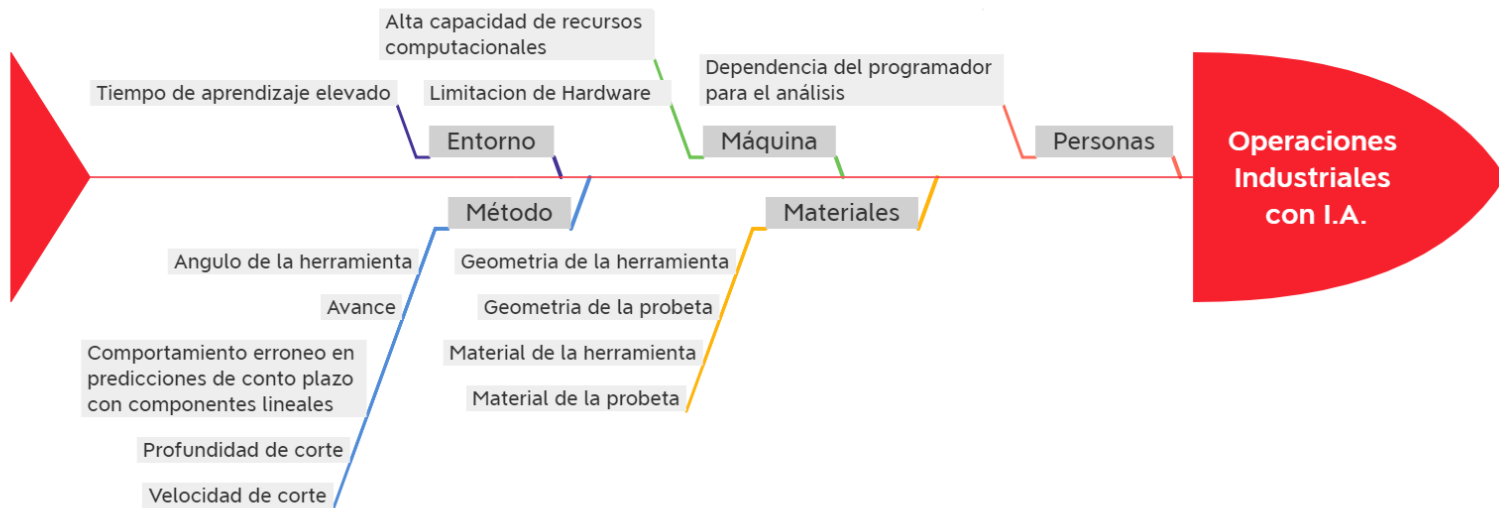


**Figura 20.** Árbol de problemas “Calidad superficial”

En la Figura 21 se recopila la información de los árboles de problemas, reestructurado en el diagrama Ishikawa que analiza factores como el “Entorno” que, dependiendo de la alta carga de información, se procesa en un tiempo elevando el aprendizaje de la estructura artificial y a su vez crea dependencia con el factor “Maquina” que para examinar los resultados y asociar en función de la variable predominante, presenta limitación en el hardware y requerimiento de recursos computacionales.

Para determinar las condiciones de los resultados se tendrán los factores “Método” y “Herramientas”; el primer factor influirá en el uso de las variables independientes (ángulo de la herramienta, avance, profundidad y velocidad de corte) y en el segundo factor para el procesamiento del mecanizado siendo dependiente de la geometría y material de las herramientas y probetas.

Sin embargo, la principal limitación es en el factor “Persona” que, para interpretar el procesamiento, vinculación y resultados, siempre se necesitara un sistema experto (experiencia del investigador).



**Figura 21.** Diagrama causa - efecto

### 1.3.1 Fundamentación legal

En la elaboración del documento varios conocimientos han sido adquiridos por los docentes de la Universidad Politécnica Salesiana, siendo el caso para el presente trabajo en la redacción y esquemas de presentación el ingeniero William Quitiaquez impartió las clases en el pregrado en la catedra de “Transferencia de calor” y en post grado en la catedra “Seminario de titulación”.

En el análisis de mecanizado y factores de corte, así como el manejo de software como SolidWorks, Minitab 19 y EasyCycle el ingeniero Xavier Vaca a través de las tutorías de las tesis enseñaba con ejemplos y material didáctico los temas en mención.

En el desarrollo de aprendizaje supervisado, no supervisado, métodos de comprobación y programación de algoritmo de clasificación y regresión el ingeniero Diego Vallejo impartió el conocimiento en las clases de la materia “Herramientas de producción”.

#### **1.4 Aspectos teóricos fundamentales**

- Metadato, información dentro de las instancias [86].
- Dendograma, grafo de la categorización segmentada DHC [87].
- Poda de árbol, decidir en un DHC cuantas agrupaciones se desea tener [88].
- Grupos artificiales, son aquellas agrupaciones que no deberían de haber o existir, es provocado al forzar la existencia de más conjuntos que los necesarios presentados [89].
- Instancia de frontera, sucede cuando la distancia entre todos los objetos del mismo grupo es igual a la medición del grupo analizado y los grupos adyacentes más cercanos al mismo [90].
- Tierra verdadera, condiciones ideales de una categorización de instancias [91].
- Cardinalidad, cuantía y disposición de componentes de un misceláneo indeterminado [92].
- Clases balanceadas, la cardinalidad de los conglomerados a estudiar es bastante similar [93].
- Algoritmo voraz, procedimiento de categorización unilateral hasta finalizar el proceso [94].
- Distancia inter clúster, longitud de cada instancia dentro del conjunto [95].
- Distancia extra clúster, longitud entre distintos conglomerados [96].

## **CAPÍTULO 2**

### **METODOLOGÍA DE LA INVESTIGACIÓN**

#### **2.1. Introducción**

Se utilizará método de aprendizaje no supervisado, para analizar la integridad superficial de los productos prismáticos circulares obtenidas en torno CNC, porque permite una solución en función de las variables independientes [97].

Se analizará la integridad superficial que se compone de la rugosidad en la superficie y tolerancias dimensionales del producto obtenido a través de la tabulación del volumen de material removido en función del tiempo en la operación de manufactura CNC, análisis comparativo de materiales y la geometría de la herramienta [98].

Se relacionará el avance, profundidad y velocidad de corte constante para la obtención del volumen de material removido en función del tiempo y para comparar la calidad superficial en cada material se cuantificará mediante un rugosímetro, tomando en consideración el tipo de herramienta y las variables mencionadas anteriormente [99].

Se analizará la comparación de la calidad del producto obtenido en función de la rugosidad superficial y tolerancia dimensional de dos aleaciones de aluminio más utilizadas en la producción de la manufactura del Ecuador, que tienen aplicaciones metal mecánicas, automotrices y aeronáuticas.

Se evaluará la capacidad y costo de producción de la investigación en la ejecución de del proyecto y se planificará el desarrollo de un algoritmo basado en la descomposición funcional para determinar la factibilidad del diseño neuronal [100].

Se estructurará el Dataset para aplicar el algoritmo de pronóstico de la calidad superficial y procesamiento secuencial, que servirá en la interpretación de los resultados a través de modelos. El análisis se centrará en modelos de control de la calidad (reconocimiento de patrones) para toma de decisiones [101].

## **2.2. Diseño de la investigación**

Actualmente no es el paradigma de utilizar software que permita únicamente hacer análisis de control; sino es utilizar el software que permita describir todos los procesos mediante el uso de estadística descriptiva (si se presenta una falla se describe con medidas de tendencia central como media, moda, mediana o con medidas de dispersión como varianza) y permita tener parámetros para toma de decisiones en la mejora y control de procesos, para posteriormente hacer una predicción de la calidad deseada, evitando un déficit en la producción.

Se tomará un muestreo y con el manejo de métodos estadísticos mediante la utilización del software “RStudio” se reduce la variabilidad de productos y procesos, para evitar posteriores dificultades dentro de los bloques de producción.

### **2.2.1. Análisis del proceso de mecanizado**


#### **2.2.1.1. Refrentado y broca de centros**

Es la operación de mecanizado en la base del cilindro (perpendicular al giro de la probeta) para posteriormente desbastar la generatriz cumpliendo las condiciones de las variables [102]. El proceso de manufactura se evidenciará en la Figura 22.



**Figura 22.** Proceso de refrentado

En la Figura 23, se presenta las probetas preparadas para torneear, que en conjunto con la broca de centros sirve para estabilizar la pieza al momento del giro [103].



**Figura 23.** Base de probeta perforada

#### **2.2.1.2. Decalaje de pieza**

En la Figura 24, se evidencia el procedimiento que sirve para ajustar y compensar los parámetros de la maquina en referencia a la probeta a mecanizar [104].



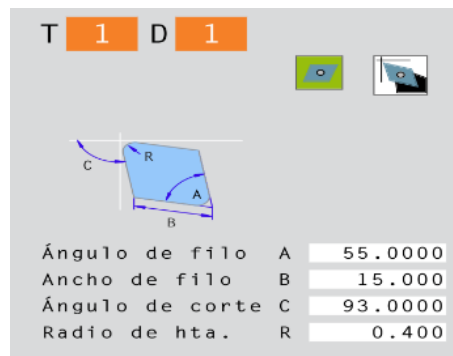
**Figura 24.** Decalaje de la probeta

#### **2.2.1.3. Aplicación de parámetros**

Dependiendo del inserto y su diseño, la herramienta presentará características específicas para su configuración en el software Easy Cycle, en el estudio del proyecto se trabajará con 3 tipos de herramientas (inserto de corte DNMG 150404 – HM NC3020 e inserto DCGX 11T304-AL H10 con recubrimientos CVD y PVD) que servirán para el proceso de cilindrado.

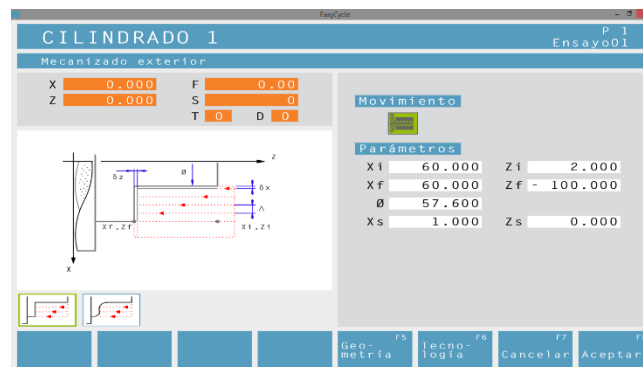
Como primer paso es recomendable la configuración de los insertos; en la Figura 25 se especificará los parámetros de las herramientas como el filo del inserto con punta a

la izquierda, la letra “T” indica la herramienta y la letra “D” en filo, el ángulo de filo de los tres insertos es 55°, el ancho de filo para el inserto DNMG es 15 mm, sin embargo, para los insertos DCGX es 11 mm, el ángulo de corte será 93° y el radio de la herramienta 0.4.



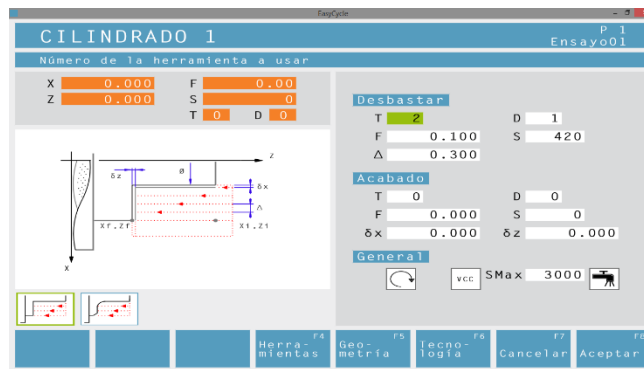
**Figura 25.** Parámetros para configuración de insertos

Para cada prueba se estableció parámetros de mecanizado, referenciando el primer ensayo en la Figura 26 se presenta la geometría del desbaste que consta con el diámetro inicial de la probeta de 60 mm, diámetro final desbastado 57.6 mm, longitud de desbaste de 100 mm y posición de seguridad de 1 y 2 mm en los ejes transversal y longitudinal respectivamente.



**Figura 26.** Parámetro, Geometría de la pieza


En la segunda sección presentada en la Figura 27 se ingresa la información analizada de los factores y niveles mediante el método Taguchi para el proceso de desbastado, T=2 y D=1 indica que es el inserto DCGX con recubrimiento CVD y filo 1, avance de 0.1 mm/rev, profundidad de 0.3 mm, velocidad constante de 420 m/min, y velocidad máxima de 3000 m/min.



**Figura 27.** Parámetro, Tecnología de mecanizado

#### 2.2.1.4. Cilindrado de probetas y tabulación de tiempo

En la Figura 28 se evidencia el proceso de cilindrado que ejecuta la programación desarrollada en Easy Cicle y se tabula el tiempo de mecanizado con el cronómetro para posteriormente ser analizado por la inteligencia artificial. Con la información censada en el proceso de cilindrado permite el análisis de tendencia y comportamiento de los resultados.



**Figura 28.** Mecanizado de probeta

#### 2.2.1.5. Medición de rugosidad

Para la medición de la rugosidad se utilizará un rugosímetro de marca Mitutoyo y modelo SJ210 exhibido en la Figura 29; permite que la unidad de accionamiento se pueda separar de la unidad de visualización mediante transferencia alámbrica de alta velocidad. Para iniciar la medición de la superficie mecanizada, primero se debe de configurar las condiciones de registro. La norma de medición que se utilizará será la estándar ISO1997, el perfil derecho de registro, parámetro de rugosidad, se utiliza el filtro de gauss para la medición, velocidad de registro de 0.25 mm/s, lambda C es la configuración del filtro de tolerancia tomando valores de 0.08, 0.25, 0.8 y 2.5 mm, sin



embargo, para el estudio se toma un  $\lambda_c = 0.8$  y la longitud de muestreo con valores de 1, 2, 3, 4 y 5, seleccionando factor 5 para tener una sección de muestro de 4 mm.



**Figura 29.** Medición de rugosidad de ensayo

En la cuantificación de la integridad superficial se procedió a medir luego de cada mecanizado dentro del Torno CNC, para tener una mejor tabulación en la medición de la rugosidad se analiza en tres puntos de la superficie de la probeta que se está mecanizando.

### **2.2.2. Programación en RStudio**

Es un programa que genera lógica a base de lenguaje de programación R, enfocado en varias ramas de la computación; para poder desarrollar la programación se necesita tener dos programas, el “R” y “RStudio” que vendrán a ser el núcleo del sistema y un entorno de trabajo respectivamente, a continuación, se presenta el esquema de programación para el análisis del estudio del presente trabajo.

#### **2.2.2.1. Instalación y activación de librerías**

En la formulación del algoritmo y ejecución de estudio lógico y gráfico, se necesita la funcionalidad del software; mediante la instalación (`install.packages`) y carga (`library`) de complementos se podrá ejecutar paquetes necesarios para el análisis; a continuación, se describe los comandos que se utilizará.

- El paquete “*readxl*”, permite hacer un llamado de archivos Excel de extensión “xls” o “xlsx”.
- El paquete “*corrplot*”, se utiliza para representar gráficamente la matriz de correlación, incluyendo una descripción detallada.
- El paquete “*dendextend*” elabora una representación de agrupaciones jerárquicas, ajustando parámetros como color y tamaño en un modelo grafico con forma de árbol.
- La librería “*cluster*”, mediante varios algoritmos agrupa las instancias.
- El paquete “*clValid*”, evalúa la consistencia del resultado del análisis de agrupamiento comparando con los grupos obtenidos.
- El paquete “*aricode*”, se utiliza en la comparación de agrupamientos estándar con  $n$  tamaños de vectores a contrastar.
- La librería “*plyr*”, es una herramienta para dividir, aplicar y combinar datos.

### 2.2.2.2.Programación de Clustering

#### 2.2.2.2.1. Importación de la tabla de ensayos

Con los resultados del mecanizado de las probetas, se reestructuró la información en un Dataset (archivo de Microsoft Excel de nombre “Tablas.xlsx”), que permitirá la importación, manipulación y análisis de tendencias en el software RStudio.

```
Datos <- read_excel("Tabla.xlsx")
View(Datos)
Datos <- read_excel("Informacion/Tesis/04. Programacion/RStudio/V05 analisis
dual/Tabla.xlsx")
View(Datos)
material <- factor(Datos$`Tipo de material`)
material
atributo = as.factor(Datos$Atributo)
atributo
Tabla
data.frame(Datos$Prueba,material,Datos$Vc,Datos$fn,Datos$ap,Datos$Rugosidad,at
ributo)
View(Tabla)
colnames(Tabla) <- c("Prueba","Material","Vc","fn","ap","Rugosidad","Atributo")
View(Tabla)
```

#### **2.2.2.2.2. Matriz de distancias**

Se calculará la distancia existente de cada instancia de las variables independientes a procesar, utilizando en método Euclidiano; para desarrollar el análisis únicamente se considerará las variables numéricas continuas.

```
d1 = dist(Tabla[,3:5],method = "euclidean")  
d1
```

#### **2.2.2.2.3. Matriz de correlación**

Se analizará la relación que existe entre las variables a estudiar. El sistema de evaluación calificará el índice de rendimiento con valores entre -1 y 1; donde los valores con tendencia de aproximación a -1 se describirán como “inversamente relacionado”, 1 como “directamente relacionado” y 0 como “no existe relación alguna”.

```
c = cor(Tabla[,3:5])  
c
```

Posteriormente al ya haber establecido los índices de correlación de las variables, se representará gráficamente los valores mediante la utilización del diagrama de calor.

```
corrplot(c)
```

Previo al análisis de clúster, se representará gráficamente el resultado de la rugosidad en función de los ensayos realizados en el laboratorio de CNC, ubicando en el eje de las abscisas el número de cada ensayo y en el eje de las ordenadas el valor de la rugosidad obtenida.

```
x=Tabla$Prueba  
y=Tabla$Rugosidad  
plot(x,y)  
text(x,y,labels=row.names(Tabla),cex = 0,01)
```

#### **2.2.2.2.4. Algoritmo de Clustering**

##### **2.2.2.2.4.1. Algoritmo particional, K-means**

Se establecerá cinco agrupaciones con sus respectivas divisiones; conformando conglomerados con atributos predominantes y utilizando en método K-means.

```
Grupos = kmeans (Tabla[,3:5],5)  
g1 = Grupos$cluster
```

```

g1
g2 = Grupos$size
g2
plot(x,y,col=c("red","blue","green","yellow","salmon")[g1],main="K-Means")

```

#### **2.2.2.2.4.2. Grupos Jerárquicos, Algoritmo DHC (Divisive Hierarchical Clustering)**

Se agrupará cinco subconjuntos mediante el método “agrupación jerárquica divisiva”, definiendo como “Big Data” los resultados de los ensayos realizados en el estudio inicial.

```

hc = hclust(d1, method = "complete" )
hc
clus3 = cutree(hc, 5)
clus3
dend = as.dendrogram(hc)
dend
dend = color_branches(dend, 5)
dend
colors = c("red","blue","green","yellow","salmon")
plot(dend, fill = colors[clus3], cex = 0.1 , main = "Clustering Jerarquico")

```

#### **2.2.2.2.5. Evaluación de rendimiento en Clustering**

##### **2.2.2.2.5.1. Algoritmo de Elbow**

Se determinará la máxima cantidad grupos a conglomerar en el estudio, permitiendo establecer un valor  $n$  que establecerá en límite entre la cantidad de grupos reales y artificiales.

```

wi = c()
for (i in 1:10)
{
  g = kmeans(Tabla[,3:5],i)
  wi[i] = g$tot.withinss
}
plot((1:length(wi)),wi, xlab="Numero de Clusters", ylab="SSE: Suma Cuadrados Internos", pch=19, col="red", type = "b")

```

##### **2.2.2.2.5.2. Método de validación interna**

##### **2.2.2.2.5.2.1. Índice de Dunn**

Se determinará la calidad del agrupamiento de los conjuntos formados, tomando valores entre cero y la tendencia al infinito para describir la peor y mejor calidad de agrupamiento respectivamente.

```
du1 = dunn(d1,g1)
du1
du2 = dunn(d1,clus3)
du2
```

#### **2.2.2.2.5.2.2. Coeficiente de silueta**

Se evaluará el tamaño y densidad de las agrupaciones con una métrica normalizada y se complementará con la representación gráfica.

```
sil1 = silhouette(g1,d1) # Silueta N
sil1
plot(sil1,col=7:9, border=NA)
sil2 = silhouette(clus3,d1)
sil2
plot(sil2,col=4:6, border=NA)
```

#### **2.2.2.2.5.3. Método de validación externa**

##### **2.2.2.2.5.3.1. ARI, Adjusted Rand Index**

Se comparará la semejanza de la agrupación de una asociación referencial con la agrupación construida.

```
ground <- factor(Tabla$Atributo)
ground
ARI1= ARI(ground,g1)
ARI1
ARI2= ARI(ground,clus3)
ARI2
```

##### **2.2.2.2.5.3.2. AMI, Adjusted Mutual Information**

Se validará la relación de información mutua entre la agrupación de una asociación referencial con la agrupación construida.

```
AMI1= AMI(ground,g1)
AMI1
AMI2= AMI(ground,clus3)
AMI2
```

##### **2.2.2.2.5.3.3. NMI, Normalized Mutual Information**

Se analizará la meta información y el factor de incertidumbre entre la agrupación de una asociación referencial con la agrupación construida.

```
NMI1= NMI(ground,g1,variant = c("joint"))
NMI1
```

```
NMI2= NMI(ground,clus3,variant = c("joint"))  
NMI2
```

### **2.2.2.3.Programación de algoritmo de clasificación**

Se importará los resultados del mecanizado de las probetas para reestructurar la información en un nuevo Dataset, que cumpla la condición para clasificación.

```
Tabla = data.frame(Tabla$Vc,Tabla$fn,Tabla$ap,Tabla$Atributo)  
View(Tabla)  
colnames(Tabla) <- c("Vc","fn","ap","Atributo")  
View(Tabla)  
m = head(Tabla, 6)
```

#### **2.2.2.3.1. División Dataset Training y test**

Se fragmentará el Dataset (instancias) para la prueba y el entrenamiento neuronal a razón de 25 y 75% respectivamente.

```
set.seed(2)  
ind_test = sample(nrow(Tabla), nrow(Tabla)/3)  
test = Tabla[ind_test,]  
View(test)  
train = Tabla[-ind_test, ]  
View(train)
```

#### **2.2.2.3.2. Entrenamiento**

Se establecerá la condición de estudio (variable dependiente) como un valor numérico continuo, para poder asociar en función de otras variables.

```
Condicion = as.numeric(train$Atributo)
```

Se desarrollará la arquitectura neuronal para el análisis de la condición de estudio en función de las variables independientes, fijando cuatro neuronas en la capa oculta.

```
ann = neuralnet(Condicion ~ Vc + fn + ap, train, hidden = c(4))  
plot(ann, rep = "best")
```

#### **2.2.2.3.3. Test**

Se pronosticará la condición de estudio utilizando la arquitectura neuronal desarrollada en la sección anterior.

```
output = compute(ann, test[,c("Vc","fn","ap")])
```

#### 2.2.2.3.4. Predicciones

Se comparará el resultado de las predicciones en relación a la condición de estudio.

```
Real = test$Atributo
Predicted = levels(m$Atributo)[round(output$net.result)]
result = data.frame(Real,Predicted)
compare = result$Real==result$Predicted
compare
```

#### 2.2.2.3.5. Rendimiento del calificador

Se evaluará la precisión de las predicciones de la arquitectura neuronal.

```
Realf = as.factor(result$Real)
Predictedf = as.factor(result$Predicted)
con = confusionMatrix(Predictedf,Realf)
con
```

#### 2.2.2.4. Programación de algoritmo de regresión

Se importará los resultados del mecanizado de las probetas para reestructurar la información en un nuevo Dataset, que cumpla la condición para regresión.

```
Datos <- read_excel("Informacion/Tesis/04. Programacion/RStudio/V05 analisis
dual/Tabla.xlsx")
View(Datos)
material <- factor(Datos$`Tipo de material`)
material
atributo = as.factor(Datos$Atributo)
atributo
Tabla =
data.frame(Datos$Prueba,material,Datos$Vc,Datos$fn,Datos$ap,Datos$Rugosidad,at
ributo)
View(Tabla)
colnames(Tabla) <- c("Prueba","Material","Vc","fn","ap","Rugosidad","Atributo")
View(Tabla)
Tabla2 = data.frame(Tabla$Vc,Tabla$fn,Tabla$ap,Tabla$Rugosidad)
View(Tabla2)
colnames(Tabla2) <- c("Vc","fn","ap","Rugosidad")
View(Tabla2)
m = head(Tabla, 6)
```

##### 2.2.2.4.1. División Dataset Training y test

Se fragmentará el Dataset (instancias) para la prueba y el entrenamiento neuronal a razón de 25 y 75% respectivamente.

```
set.seed(2)
```

```
ind_test = sample(nrow(Tabla2), nrow(Tabla2)/3)
test2 = Tabla2[ind_test,]
View(test2)
train2 = Tabla2[-ind_test, ]
View(train2)
```

#### **2.2.2.4.2. Entrenamiento**

Se establecerá el valor de la rugosidad como la variable dependiente, para poder asociar en función de otras variables.

```
Condicion2 = as.numeric(train2$Rugosidad)
```

Se desarrollará la arquitectura neuronal para el análisis de la condición de estudio en función de las variables independientes, fijando tres neuronas en la capa oculta.

```
ann = neuralnet(Condicion2 ~ Vc + fn + ap, train2, hidden = c(3))
plot(ann, rep = "best")
```

#### **2.2.2.4.3. Test**

Se pronosticará la condición de estudio utilizando la arquitectura neuronal desarrollada en la sección anterior.

```
output = compute(ann, test2[,c("Vc","fn","ap")])
```

#### **2.2.2.4.4. Predicciones**

Se comparará el resultado de las predicciones en relación a la condición de estudio.

```
Real2 = test2$Rugosidad
Predicted2 = levels(m$Rugosidad)[round(output$net.result)]
result2 = data.frame(Real2,Predicted2)
compare = result$Real==result$Predicted
compare
```

#### **2.2.2.4.5. Rendimiento del calificador**

Se evaluará la precisión de las predicciones de la arquitectura neuronal.

```
Realf = as.factor(result$Real)
Predictedf = as.factor(result$Predicted)
con = confusionMatrix(Predictedf,Realf)
con
```



### **2.3. Modalidad de la investigación**

En el presente estudio se utiliza la modalidad de investigación comparativa, porque permite determinar las diferencias entre dos o más variables analizadas.

### **2.4. Tipo de investigación**

En el aprendizaje no supervisado se utiliza la investigación de campo para examinar y registrar directamente el objeto de estudio (integridad superficial, tiempo y caudal) y correlacional para determinar la relación entre las tres variables independientes (profundidad, avance y tipo de herramienta) para medir similitudes y diferencias. En el aprendizaje supervisado se utilizará la investigación experimental para modificar las condiciones en la indagación neural artificial en la mejora de las condiciones del objeto de estudio (regresión o clasificación).

### **2.5. Métodos de investigación**

En la presente investigación se va a utilizar el método cuantitativo para comparar información con orientación numérica mediante métodos estadísticos descriptivos y estadísticos multi variada.

### **2.6. Técnicas e instrumentos**

#### **2.6.1. Técnicas**

##### **2.6.1.1. Análisis estadísticos**

Consiste en el censo, compilación y descripción de la información para la caracterización de resultados con bajos o grandes volúmenes de datos [105].

##### **2.6.1.2. Red neuronal Artificial**

En la investigación desarrollada se utilizará este método para agrupar y predecir resultados de la calidad superficial en función del tiempo de mecanizado.

#### **2.6.2. Instrumentos**

##### **2.6.2.1. Torno CNC ECOMAT E-200**

Es una máquina herramienta que trabaja a través del control numérico computarizado; sirve para hacer operaciones de mecanizado mediante movimientos de rotación, avance y profundidad, con velocidad de rotación máxima de 4000 rpm.

#### 2.6.2.2. Rugosímetro Mitutoyo SJ 210

En la Figura 30 se presenta la herramienta que sirve para determinar la profundidad de la rugosidad en superficies; en el estudio a realizar se utilizara en el censo de la variable dependiente en los ensayos.



Figura 30. Rugosímetro Mitutoyo SJ 210

#### 2.6.2.3. Porta herramienta SDJCR 2020 K11

En la Figura 31 se exhibe la porta herramienta para los insertos de corte que se utilizara en el torneado en la maquina CNC, de dimensiones técnicas como se presenta en la sección de anexos.



Figura 31. Porta herramienta SDJCR 2020 K11

#### 2.6.2.4. Inserto de corte DCGX 11T304-AL H10

Es una herramienta de precisión con forma rómbica de 55°, ángulo de incidencia de 7°, tolerancia dimensional de + 0.013 mm por metro, de diseño especial, 11.228 mm de longitud de la arista del filo, 3.97 mm de espesor, 0.4 mm de radio de nariz.



**Figura 32.** Inserto de corte DCGX 11T304-AL H10 (CVD)

En el mecanizado del estudio se consideró dos tipos de recubrimiento, por deposición física de vapor o PVD (Figura 32) y deposición química de vapor o CVD (Figura 33), dirección de corte al lado izquierdo, categoría 10, composición de carburo de tungsteno y recomendación de corte para materiales no ferrosos.



**Figura 33.** Inserto de corte DCGX 11T304-AL H10 (PVD)

#### **2.6.2.5. Inserto de corte DNMG 150404 – HM NC3020**

Es una herramienta de precisión con forma rómbica de 55°, ángulo de incidencia de 0°, tolerancia dimensional de + 0.08 mm por metro, con orificio cilíndrico y rompe virutas se doble lado, 12.70 mm de longitud de la arista del filo, 4.76 mm de espesor, 0.4 mm de radio de nariz, dirección de corte a ambos lados, categoría alta calidad, composición de carburo de tungsteno y recomendación de corte para materiales no ferrosos, inoxidable, fundiciones, aceros al carbono, aleaciones termorresistentes y aceros endurecidos.

#### 2.6.2.6. Probeta AA 7075 – T6

Conocido comercialmente como Produx, presentado en la Figura 34, es ampliamente utilizado en matricería. Tiene una resistencia a la rotura de 524 MPa, resistencia a la deformación plástica de 455 MPa, elongación máxima del 8%, 150 Brinell de dureza y conductividad térmica de  $900 \frac{W}{mK}$ .



Figura 34. Probeta AA 7075 – T6

#### 2.6.2.7. Probeta AA 6061 – T6

Generalmente utilizado en instalaciones de luminaria, reflexión solar, piezas automotrices y de maquinaria, presentado en la Figura 35. Tiene una resistencia a la rotura de 290 MPa, resistencia a la deformación plástica de 241 MPa, 95 Brinell de dureza y conductividad térmica de  $1250 \frac{W}{mK}$ .



Figura 35. Probeta AA 6061 – T6

## 2.7. Operacionalización de las variables

### 2.7.1. Variable dependiente

A continuación, se presenta la operacionalización de las variables dependientes describiendo la conceptualización, categorías, indicadores e índice.

**Tabla 2.** Operacionalización de variables dependientes

Conceptualización	Categorías	Indicadores	Índice
La innovación tecnológica demanda requerimientos de calidad en productos de manufactura. Para poder evolucionar junto con la revolución del mercado actual se debe de disminuir la influencia de los defectos que lo provocan. La integridad superficial representa el indicador eficacia que permite tabular la aceptación del cliente por el producto.	Integridad Superficial	Rugosidad 1 (Ra1)	(0.74 – 8.85) [μm]
		Rugosidad 2 (Ra2)	
		Rugosidad 3 (Ra3)	
		R promedio	
Determinar la cantidad de material desalojado en operaciones de mecanizado es de vital importancia en procesos de producción a gran escala, aprovechar todos los recursos generando la menor cantidad de desperdicios permite un ahorro económico y reduce el costo de producción.	Volumen de material removido	Tiempo de mecanizado (t)	(17.24 – 155.41) [s]
		Caudal (Q)	(0.14 - 2.19) [cm <sup>3</sup> /s]

### 2.7.2. Variable independiente

En la Tabla 3 se presenta las operacionalizaciones de las variables independientes; sin embargo, en el análisis de los parámetros del estudio se considera que la velocidad de corte y el volumen de material removido sean constantes para examinar la cantidad de caudal en función del tiempo de mecanizado y la rugosidad este en función de la velocidad del eje.

**Tabla 3.** Operacionalización de variables independientes

Conceptualización	Categorías	Indicadores	Índice
En operaciones industriales la vinculación más grande que existe es el comercio de la mercancía producida, para la creación de un producto manufacturado de buena calidad y estética se debe de tener un riguroso control de variables de mecanizado como lo son la velocidad del eje, profundidad, avance y tiempo de mecanizado.	Parámetros de mecanizado	Velocidad de corte	(420) [m/min]
		Profundidad (ap)	(0.3 - 1.2) [Adimensional]
		Avance (fn)	(0.1 - 0.3) [mm/rev]
		Tipo de herramienta	DCGX (PVD) DCGX (CVD) DNMG

## 2.8. Población y muestra

### 2.8.1. Población

Es el desarrollo de la cantidad necesaria de ensayos en el análisis de los parámetros de mecanizado en aleaciones de AA 6061 - T6 y AA 7075 - T6, para la tabulación de los sujetos de estudio del proyecto.

### 2.8.2. Muestra

#### 2.8.2.1. Factores y niveles

En la Tabla 4 se presentan los factores y niveles que intervienen en el desarrollo del estudio (integridad superficial); no obstante, la velocidad de corte será constante de 420 m/min, para el análisis del caudal se relaciona el volumen constante del material removido de 22.2 cm<sup>3</sup> y el tiempo de cada mecanizado tabulado con un cronometro.

**Tabla 4.** Factores y niveles

Factores		Niveles	
Profundidad [mm]	0.3	0.6	1.2
Avance [mm/rev]	0.1	0.2	0.3
Herramienta	DCGX (CVD)	DCGX (PVD)	DNMG

### 2.8.2.2.Método Taguchi

Es una herramienta de mejora en procesos, identifica y evalúa factores controlados con mayor consistencia del procedimiento operativo. En la presente investigación a través del software Minitab 19 se utilizará el método para hacer la combinación de los niveles y aplicar en cada número de ensayos que el programa indica.

**Tabla 5.** Arreglo ortogonal de parámetros de corte

Ensayo	Profundidad [ap]	Avance [fn]	Herramienta
1	0.3	0.1	DCGX (CVD)
2	0.3	0.2	DCGX (PVD)
3	0.3	0.3	DNMG
4	0.6	0.1	DCGX (PVD)
5	0.6	0.2	DNMG
6	0.6	0.3	DCGX (CVD)
7	1.2	0.1	DNMG
8	1.2	0.2	DCGX (CVD)
9	1.2	0.3	DCGX (PVD)

## 2.9. Resultados de la técnica aplicada

En la Tabla 6 se presenta los resultados de la aplicación de los parámetros de mecanizado en la probeta de aluminio AA 6061 T6.

**Tabla 6.** Resultados de mecanizado AA 6061 T6.

<b>aP</b> [mm]	<b>f<sub>n</sub></b> [mm/rev]	<b>Herramienta</b>	<b>Tiempo</b> [s]	<b>Q</b> [cm <sup>3</sup> /s]	<b>Ra1</b> [μm]	<b>Ra2</b> [μm]	<b>Ra3</b> [μm]	<b>Ra</b> [μm]
0.3	0.1	DCGX (CVD)	155.41	0.1426	0.944	0.942	1.013	0.966
0.3	0.2	DCGX (PVD)	62.23	0.3561	3.728	3.724	3.727	3.726
0.3	0.3	DNMG	43.04	0.5149	6.921	6.969	6.954	6.948
0.6	0.1	DCGX (PVD)	59.75	0.3709	0.730	0.858	0.769	0.786
0.6	0.2	DNMG	32.72	0.6772	2.926	2.982	3.025	2.978
0.6	0.3	DCGX (CVD)	28.44	0.7793	7.838	7.794	7.769	7.800
1.2	0.1	DNMG	34.52	0.6419	1.117	1.054	1.259	1.143
1.2	0.2	DCGX (CVD)	21.43	1.0341	3.549	3.328	2.922	3.266
1.2	0.3	DCGX (PVD)	17.23	1.2858	8.923	8.752	8.489	8.721

En la Tabla 7 se presenta los resultados de la aplicación de los parámetros de mecanizado en la probeta de aluminio AA 7075 T6.

**Tabla 7.** Resultados de mecanizado AA 7075 T6.

<b>aP</b> [mm]	<b>f<sub>n</sub></b> [mm/rev]	<b>Herramienta</b>	<b>Tiempo</b> [s]	<b>Q</b> [cm <sup>3</sup> /s]	<b>Ra1</b> [μm]	<b>Ra2</b> [μm]	<b>Ra3</b> [μm]
0.3	0.1	DCGX (CVD)	117.95	0.1879	0.788	0.663	0.756
0.3	0.2	DCGX (PVD)	62.33	0.3555	3.005	2.993	3.060
0.3	0.3	DNMG	44.27	0.5006	6.948	6.980	7.087
0.6	0.1	DCGX (PVD)	61.49	0.3604	0.924	0.999	1.032
0.6	0.2	DNMG	33.86	0.6546	3.061	3.142	3.174
0.6	0.3	DCGX (CVD)	24.40	0.9081	8.681	8.518	8.473
1.2	0.1	DNMG	30.57	0.7248	1.448	1.449	1.316
1.2	0.2	DCGX (CVD)	19.73	1.1230	4.524	4.390	4.713
1.2	0.3	DCGX (PVD)	18.75	1.1821	9.021	8.533	8.990



## CAPÍTULO 3

### ANÁLISIS E INTERPRETACIÓN DE RESULTADOS

#### 3.1. Introducción

En este capítulo se analiza los resultados de los dos estudios complementarios de la investigación, el proceso de mecanizado CNC en el laboratorio y la aplicación de red neuronal artificial.

Para el proceso de mecanizado en la determinación del caudal de viruta evacuada, tiempo de mecanizado y rugosidad en las superficies de los ensayos, se tabulo el proceso utilizando los parámetros descritos anteriormente.

En la aplicación de la red neuronal artificial se estructuro en tres secciones dependiendo del tipo de material, dos secciones con un solo tipo de material y una en análisis conjunto.

#### 3.2. Descripción de la situación actual

##### 3.2.1. Análisis de resultados del proceso de mecanizado

En la Tabla 8 se exhibe los resultados del mecanizado de las probetas de aluminio, presentando una rugosidad mínima de 0.736 y máxima de 8.848  $\mu\text{m}$ , un caudal de viruta evacuada de 0.143 a 2.185  $\text{cm}^3/\text{s}$  y tiempos de mecanizados de 10.14 a 155.41 segundos.

**Tabla 8.** Presentación de resultados del proceso de mecanizado

Ensayo	Material	ap [mm]	fn [mm/rev]	Herramienta	t [s]	Q [ $\text{cm}^3/\text{s}$ ]	Ra [ $\mu\text{m}$ ]
1	AA 6061 T6	0.3	0.1	DCGX (CVD)	155.41	0.1426	0.966
2	AA 6061 T6	0.3	0.2	DCGX (PVD)	62.23	0.3561	3.726
3	AA 6061 T6	0.3	0.3	DNMG	43.04	0.5149	6.948
4	AA 6061 T6	0.6	0.1	DCGX (PVD)	59.75	0.3709	0.786
5	AA 6061 T6	0.6	0.2	DNMG	32.72	0.6772	2.978
6	AA 6061 T6	0.6	0.3	DCGX (CVD)	28.44	0.7793	7.800
7	AA 6061 T6	1.2	0.1	DNMG	34.52	0.6419	1.143
8	AA 6061 T6	1.2	0.2	DCGX (CVD)	21.43	1.0341	3.266
9	AA 6061 T6	1.2	0.3	DCGX (PVD)	17.23	1.2858	8.721
10	AA 7075 T6	0.3	0.1	DCGX (CVD)	117.95	0.1879	0.736

Continuación de Tabla 8. Presentación de resultados del proceso de mecanizado

11	AA 7075 T6	0.3	0.2	DCGX (PVD)	62.33	0.3555	3.019
12	AA 7075 T6	0.3	0.3	DNMG	44.27	0.5006	7.005
13	AA 7075 T6	0.6	0.1	DCGX (PVD)	61.49	0.3604	0.985
14	AA 7075 T6	0.6	0.2	DNMG	33.86	0.6546	3.126
15	AA 7075 T6	0.6	0.3	DCGX (CVD)	24.40	0.9081	8.557
16	AA 7075 T6	1.2	0.1	DNMG	30.57	0.7248	1.404
17	AA 7075 T6	1.2	0.2	DCGX (CVD)	19.73	1.1230	4.542
18	AA 7075 T6	1.2	0.3	DCGX (PVD)	18.75	1.1821	8.8480


### 3.2.2. Análisis de resultados en función del tiempo

En la Tabla 9 se presenta los tiempos de mecanizado en función de los ensayos, tomando de referencia los programas EasyCycle y SolidWorks en conjunto con el tiempo real en la elaboración de cada ensayo.

**Tabla 9.** Tiempos de ensayos

Ensayo	Material	Solid works [s]	Easy Cycle [s]	Tiempo Real [s]
1	AA 6061 T6	179	110	155.41
2	AA 6061 T6	104	56	62.23
3	AA 6061 T6	81	38	43.04
4	AA 6061 T6	87	55	59.76
5	AA 6061 T6	60	41	32.72
6	AA 6061 T6	52	29	28.44
7	AA 6061 T6	70	57	34.52
8	AA 6061 T6	55	32	21.43
9	AA 6061 T6	58	76	17.23
10	AA 7075 T6	179	110	117.95
11	AA 7075 T6	104	56	62.33
12	AA 7075 T6	81	38	44.27
13	AA 7075 T6	87	55	61.49
14	AA 7075 T6	60	41	33.86
15	AA 7075 T6	52	29	24.40
16	AA 7075 T6	70	57	30.57
17	AA 7075 T6	55	32	19.73
18	AA 7075 T6	58	76	18.75

En la Figura 36 se representa el censo de los tiempos de mecanizado, se puede concluir que el tiempo real muestra relación directamente proporcional con los resultados simulados; sin embargo, el tiempo real en relación a los tiempos en EasyCycle y SolidWorks son del 75.07% y 97.17% respectivamente, concluyendo que mejor relacionados están entre el tiempo real y el simulado en SolidWorks.




**Figura 36.** Comparativa temporal

Al analizar comparativamente los resultados de la rugosidad en función de los nueve ensayos realizados por cada material, se puede concluir que, se tiene el 55.56% de índices más altos con la aleación AA 6061 T6 pese al tener menor dureza y resistencia a la tensión que la aleación AA 7075 T6, describiendo un comportamiento grafico similar en las dos aleaciones como se exhibe en la Figura 37.


**Tabla 10.** Índices de tiempo de mecanizado

Ensayo	Tiempo AA 6061 T6	Tiempo AA 6061 T7	Variación Porcentual [%]
1	155,41	117,95	24.1
2	62,23	62,33	0.16
3	43,04	44,27	2.77
4	59,75	61,49	2.82
5	32,72	33,86	3.35
6	28,44	24,40	14.17
7	34,52	30,57	11.44
8	21,43	19,73	7.92
9	17,23	18,75	8.07




**Figura 37.** Rugosidad en función del número de ensayo

Al analizar la eficiencia del proceso se puede deducir que la rugosidad está relacionada inversamente con el tiempo de mecanizado a razón promedio del 55.11%, lo que quiere decir a mayor tiempo menor índice de rugosidad, como se presenta en la Figura 38.




**Figura 38.** Tiempo de mecanizado en función del número de ensayo

En la Figura 39 se puede evidenciar tres graficas de la rugosidad en función de la profundidad, ordenadas de acuerdo al avance en un orden de izquierda a derecha de 0.1, 0.2, 0.3 mm/rev respectivamente. Se puede concluir que mayores índices de rugosidad se obtiene con una profundidad de 1.2 mm y material AA 7075 T6; a excepción con el material AA 6061 T6 con un avance de 0.2 mm/rev, se obtuvo mayor rugosidad con una profundidad de 0.3 mm.




**Figura 39.** Rugosidad en función de la Profundidad

En la Figura 40 se presentan tres graficas de la rugosidad en función del avance, ordenadas de acuerdo la profundidad en un orden de izquierda a derecha de 0.3, 0.6, 1.2 mm respectivamente. Se puede concluir que mayores índices de rugosidad se obtiene con un avance de 0.3 mm/rev y material AA 7075 T6.




**Figura 40.** Rugosidad en función del avance

En la Figura 41 se exhiben tres graficas del caudal en función del avance, ordenadas de acuerdo la profundidad en un orden de izquierda a derecha de 0.3, 0.6, 1.2 mm respectivamente. Se puede concluir que mayor caudal de material de viruta evacuada es con avance de 0.3 mm/rev y material AA 6061 T6; a excepción de una profundidad de 0.6 mm y material AA 7075 T6.



**Figura 41.** Caudal en función del avance

En la Figura 42 se muestra tres graficas del caudal en función de la profundidad, ordenadas de acuerdo al avance en un orden de izquierda a derecha de 0.1, 0.2, 0.3 mm/rev respectivamente. Se puede concluir que mayor caudal de material de viruta evacuada es obtenido con una profundidad de 1.2 mm y material AA 7075 T6; a excepción con el material AA 6061 T6 con un avance de 0.3 mm/rev.



**Figura 42.** Rugosidad en función de la profundidad

### 3.2.3. Análisis de clustering

#### 3.2.3.1. Análisis del aluminio AA 6061 T6

##### 3.2.3.1.1. Correlación de las variables

En el siguiente mapa de calor se presenta la relación de las variables independientes utilizadas para el estudio de agrupación de los resultados de la rugosidad del aluminio AA 6061 T6. Exhibiendo un comportamiento directamente proporcional entre las variables “velocidad de corte” y “avance” a razón de 31.96%, “velocidad de corte” y “profundidad” a razón de 93.91%; sin embargo, entre “avance” y “profundidad” no existe relación alguna.





Figura 43. Matriz de correlación AA 6061 T6


##### 3.2.3.1.2. Algoritmo K-mean

En la Figura 44 se presenta gráficamente las instancias de la rugosidad en función del número de los ensayos realizados, para posteriormente ser agrupados en relación a la característica más notable del etiquetado.



**Figura 44.** Rugosidad en función del ensayo – AA 6061 T6

En el reconocimiento de patrones para las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo K-mean ha tomado de referencia el avance para la conglomeración de cada grupo, presentando que para el conjunto 1 toma en ensayo 9, para el conjunto 2 agrupo los ensayos 5 y 6, para el conjunto 3 agrupa los ensayos 7 y 8, para el conjunto 4 agrupa los ensayos 3 y 5 y para el grupo 5 los ensayos 1 y 2, como se puede observar en la Figura 45.




**Figura 45.** Algoritmo K-means - AA 6061 T6

### 3.2.3.1.3. Algoritmo DHC

Para el reconocimiento de patrones en las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo DHC ha tomado de referencia el avance para la conglomeración de cada grupo, presentando que para el conjunto 1 toma en ensayo 9,




para el conjunto 2 agrupo los ensayos 8 y 7, para el conjunto 3 agrupa los ensayos 6 y 5, para el conjunto 4 agrupa los ensayos 1 y 2 y para el grupo 5 los ensayos 3 y 4, como se puede observar en la Figura 46.



**Figura 46.** Dendrograma AA 6061 T6

#### 3.2.3.1.4. Algoritmo de Elbow

El algoritmo Elbow en la determinación de grupos delimita los límites de frontera a  $n$  grupos para la categorización, en la Figura 47 presenta que el límite máximo de creación de grupos reales es entre 4 y 5, lejos de los mismos serán artificiales los grupos.




**Figura 47.** Algoritmo de elbow AA 6061 T6

### 3.2.3.1.5. Validación interna


Para analizar la separación entre cada grupo formado se tendrá el Índice de Dunn, un valor oscilante entre cero e infinito; en el algoritmo de K-means como en el DHC indican que su valor es 0.619536, lo que se deduce es que la distancia entre cada conglomerado es muy pequeña.

El coeficiente de silueta es una métrica de control estándar; en la Figura 48 se evalúa el rendimiento de la agrupación K-means. En el primer grupo se tiene un coeficiente del 0% debido a que es un conjunto de un solo elemento, el segundo y el cuarto grupo tienen un coeficiente del 33%, en el tercer grupo 17% y el último 52% de rendimiento.



**Figura 48.** Coeficiente de silueta K-means AA 6061 T6

En la Figura 49 se evalúa el rendimiento de la agrupación DHC, concluyendo que el rendimiento más bajo es del cuarto grupo con coeficiente del 17%, el segundo y tercero del 22% y el primero del 52% de rendimiento, el rendimiento del quinto grupo no se considera por ser un conjunto de un solo elemento.



**Figura 49.** Coeficiente de silueta DHC, AA 6061 T6


### 3.2.3.1.6. Validación externa

En los clustering K-means y DHC al tener iguales coeficientes se concluye, que ambos clustering tienen un agrupamiento del 4.7%, 61.03% de coincidencia entre los elementos del clúster y 47.23% de desorden entre los clústeres y la etiqueta del atributo.

### 3.2.3.2. Análisis del aluminio AA 7075 T6

#### 3.2.3.2.1. Correlación de las variables


En el siguiente mapa de calor se presenta la relación de las variables independientes utilizadas para el estudio de agrupación de los resultados de la rugosidad del aluminio AA 7075 T6. Exhibiendo un comportamiento directamente proporcional entre las variables “velocidad de corte” y “avance” a razón de 31.96%, “velocidad de corte” y “profundidad” a razón de 93.90%; sin embargo, entre “avance” y “profundidad” no existe relación alguna.



**Figura 50.** Matriz de correlación AA 7075 T6


### 3.2.3.2.2. Algoritmo K-mean

En la Figura 51 se presenta gráficamente las instancias de la rugosidad en función del número de los ensayos realizados, para posteriormente ser agrupados en relación a la característica más notable del etiquetado.



**Figura 51.** Rugosidad en función del ensayo – AA 7075 T6


En el reconocimiento de patrones para las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo K-mean ha tomado de referencia el avance para conglomerar cada grupo, presentando que para el conjunto 1 toma los ensayos 4 y 5, para el conjunto 2 agrupo el ensayo 8, para el conjunto 3 agrupa el ensayo 9, para el conjunto 4 agrupa los ensayos 1, 2 y 3 y para el grupo 5 los ensayos 6 y 7, como se puede observar en la Figura 52.



**Figura 52.** Algoritmo K-means – AA 7075 T6

### 3.2.3.2.3. Algoritmo DHC


Para el reconocimiento de patrones en las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo DHC ha tomado de referencia el avance para conglomerar de cada grupo, presentando que para el conjunto 1 toma en ensayo 9, para el conjunto 2 agrupo los ensayos 8 y 7, para el conjunto 3 agrupa los ensayos 6 y 5, para el conjunto 4 agrupa los ensayos 1 y 2 y para el grupo 5 los ensayos 3 y 4, como se puede observar en la Figura 53.



**Figura 53.** Dendograma AA 7075 T6

#### 3.2.3.2.4. Algoritmo de Elbow

En la Figura 54 se analiza que el límite máximo para la creación de grupos reales es 5; lejos de la frontera las agrupaciones tienden a ser artificiales, disminuyendo los coeficientes de aglomeración.




**Figura 54.** Algoritmo de Elbow – AA 7075 T6

#### 3.2.3.2.5. Validación interna


Con el Índice de Dunn se puede deducir que la separación de cada grupo en los algoritmos K-mean y DHC es 0.5682092 y 0.619536 respectivamente. Concluyendo que es muy pequeña la separación de los etiquetados y que está mejor separado en el algoritmo DHC.

En la Figura 55 se evalúa el rendimiento de la agrupación K-means. El mejor coeficiente es el del grupo 4 con una métrica del 46%, luego el primer grupo con una métrica del 42% y la más baja el quinto grupo con 17%, no obstante, los grupos 2 y 3 no se los considera debido a que son grupos de un solo elemento; el coeficiente promedio es del 28% de toda la agrupación.



**Figura 55.** Coeficiente de silueta K-means – AA 7075 T6

En la Figura 56 se evalúa el rendimiento del algoritmo DHC. Concluyendo que la mejor agrupación es del coeficiente del grupo 1 con una métrica del 52%, luego los grupos 2 y 3 con una métrica del 33% y la más baja el cuarto grupo con 17%, no obstante, el grupo 5 no se los considera debido a que son grupos de un solo elemento; el coeficiente promedio es del 30% de toda la agrupación.



**Figura 56.** Coeficiente de silueta DHC – AA 7075 T6

### 3.2.3.2.6. Validación externa


Con el resultado de los coeficientes se concluye que, el ARI del algoritmo DHC tiene un agrupamiento del 2.17% y el K-meas describe un comportamiento desordenado del 78.83%, el AMI DHC (51.29%) con respecto al AMI K-means de (39.32%) posee mejor coincidencia de información y la entropía de los algoritmos DHC y K-meas son del 39.69% y 27.25% respectivamente.

### 3.2.3.3. Análisis combinado de aluminios AA 6061 T6 y AA 7075 T6

#### 3.2.3.3.1. Correlación de las variables

En el siguiente mapa de calor se presenta la relación de las variables independientes utilizadas para el estudio de agrupación de los resultados de la rugosidad de las dos aleaciones de aluminio. Exhibiendo un comportamiento directamente proporcional entre las variables “velocidad de corte” y “avance” a razón de 31.96%, “velocidad de corte” y “profundidad” a razón de 93.91%; sin embargo, entre “avance” y “profundidad” no existe relación alguna y las variables “material” y “herramienta” no se relacionan con otra variable.






**Figura 57.** Matriz de correlación conjunta


### 3.2.3.3.2. Algoritmo K-mean

En la Figura 58 se presenta gráficamente las instancias de la rugosidad en función del número de los ensayos realizados, para posteriormente ser agrupados en relación a la característica más notable del etiquetado.



**Figura 58.** Rugosidades en función de los ensayos

En el reconocimiento de patrones para las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo K-mean ha tomado de referencia el avance para conglomerar cada grupo, presentando que para el conjunto 1 toma los ensayos 5, 6, 14 y 15, para el conjunto 2 agrupo los ensayos 7, 8, 16 y 17, para el conjunto 3 agrupa los ensayos 1, 2, 10 y 11, para el conjunto 4 agrupa los ensayos 3, 4, 12 y 13 y para el grupo 5 los ensayos 9 y 18, como se puede observar en la Figura 59.




**Figura 59.** Algoritmo K-means

### 3.2.3.3.3. Algoritmo DHC

Para el reconocimiento de patrones en las instancias de rugosidades obtenidas en el laboratorio, el resultado del algoritmo DHC ha tomado de referencia el avance para conglomerar cada grupo, presentando que para el conjunto 1 toma en ensayo 1, 2, 10


y 11, para el conjunto 2 agrupo los ensayos 3, 4, 12 y 13, para el conjunto 3 agrupa los ensayos 5, 6, 14 y 15, para el conjunto 4 agrupa los ensayos 7, 8, 16 y 17 y para el grupo 5 los ensayos 9 y 18, como se puede observar en la Figura 60.



**Figura 60.** Dendograma

#### 3.2.3.3.4. Algoritmo de Elbow

En la Figura 61 se analiza el límite máximo para la creación de grupos reales, la curva en el punto 6 describe un pico, indicando una tendencia de comportamiento, desde el punto 7 comienza el número de clúster límite que provoca la creación de grupos artificiales.




**Figura 61.** Algoritmo de Elbow

### 3.2.3.3.5. Validación interna


Con el Índice de Dunn se puede deducir que la separación de cada grupo en los algoritmos K-mean y DHC es 0.619536. Concluyendo que es muy pequeña la distancia de los etiquetados y que los dos algoritmos de agrupamiento se asemejan mucho.

En la Figura 62 se evalúa el rendimiento de la agrupación K-means. El mejor coeficiente es del grupo 5 con una métrica del 100%, seguido del tercer grupo con una métrica del 68%, el primero y cuarto grupo con una métrica del 55% y la más baja el segundo grupo con 45%, no tienen presencia de grupos de un solo elemento y el coeficiente promedio de toda la agrupación es 61%.



**Figura 62.** Coeficiente de silueta K-means

El diagrama de silueta presentado en la Figura 63 evalúa el algoritmo DHC, asemejando su análisis de agrupamiento al algoritmo K-means. El mejor coeficiente es del grupo 5 con una métrica del 100%, el primer grupo con una métrica del 68%, el segundo y tercer grupo con una métrica del 55% y la más baja el cuarto grupo con 45%, no tienen presencia de grupos de un solo elemento y el coeficiente promedio de toda la agrupación es 61%.



**Figura 63.** Coeficiente de silueta DHC

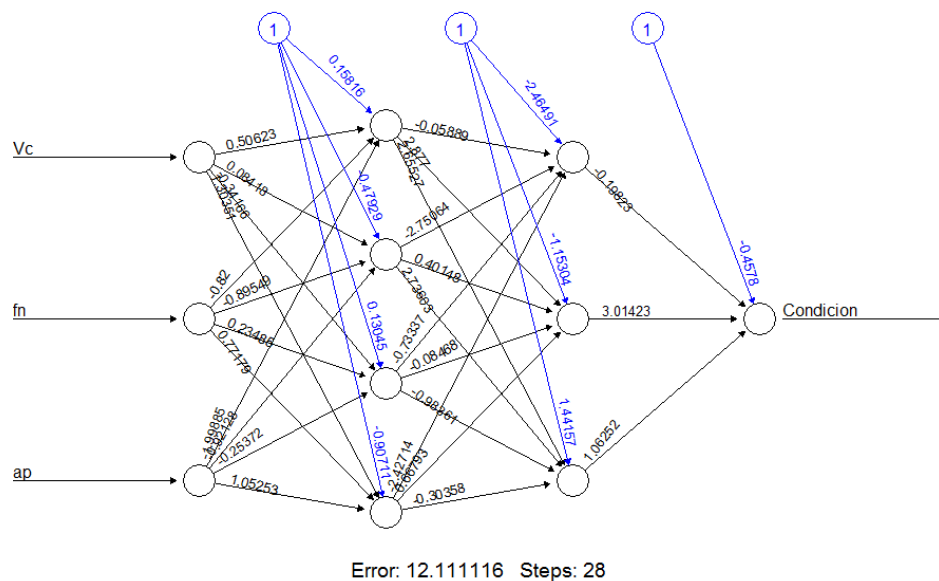
### 3.2.3.3.6. Validación externa

Con el resultado de los coeficientes y al ser iguales se concluye que, los algoritmos tienen semejanza del 18.94%, coincidencia del 49.45% y entropía del 35.58%.

### 3.2.4. Análisis de red neuronal

#### 3.2.4.1. Análisis del aluminio AA 6061 T6

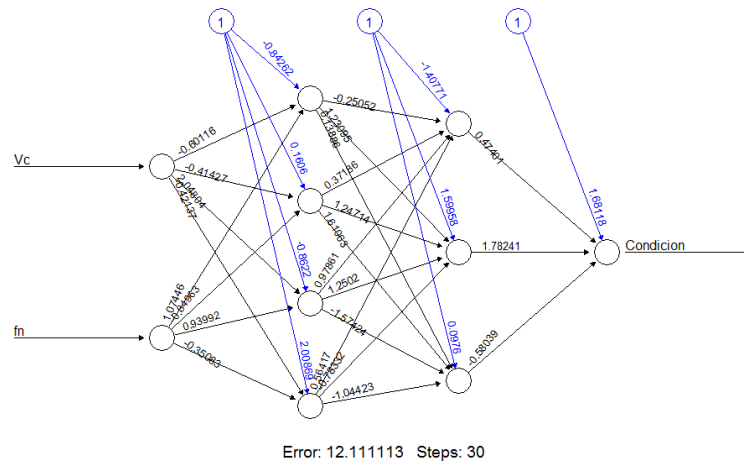
##### 3.2.4.1.1. Estructura Vc, fn y ap



**Figura 64.** Arquitectura Vc-fn-ap, AA 6061 T6

En la Figura 64 se presenta la primera condición de la arquitectura de la red neuronal para el material AA 6061 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc, fn y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 12.11%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Excelente”.

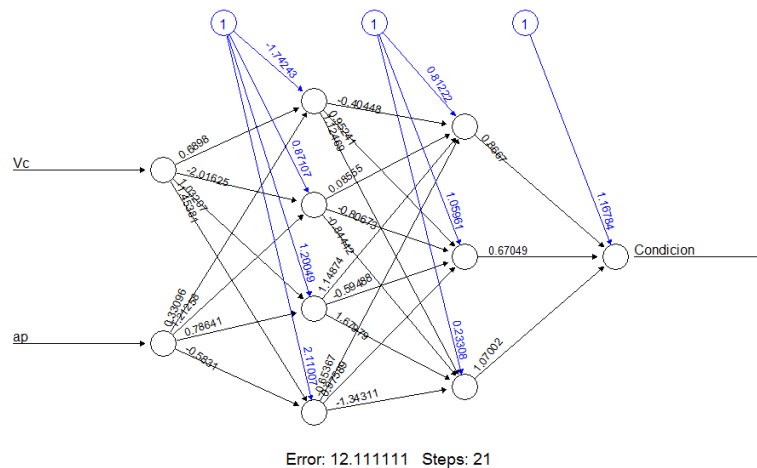
### 3.2.4.1.2. Estructura Vc y fn



**Figura 65.** Arquitectura Vc-fn, AA 6061 T6

En la Figura 65 se presenta la segunda condición de la arquitectura para la red neuronal del material AA 6061 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc y fn, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 12.11%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Excelente”.

### 3.2.4.1.3. Estructura Vc y ap




**Figura 66.** Arquitectura Vc-ap, AA 6061 T6

En la Figura 66 se presenta la tercera condición de la arquitectura para la red neuronal del material AA 6061 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 12.11%. Para este

caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Excelente”.

#### 3.2.4.1.4. Estructura fn y ap



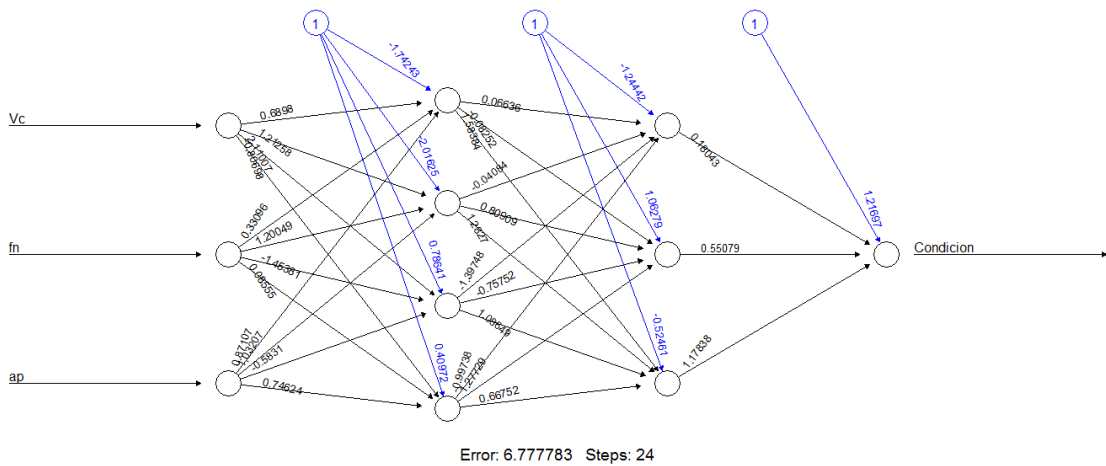
**Figura 67.** Arquitectura fn-ap, AA 6061 T6

En la Figura 67 se presenta la cuarta condición de la arquitectura para la red neuronal del material AA 6061 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables fn y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 0.002097%. Para este caso se tiene una precisión del 100%, en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” y la predicción fue de etiqueta “Regular”.



### 3.2.4.2. Análisis del aluminio AA 7075 T6

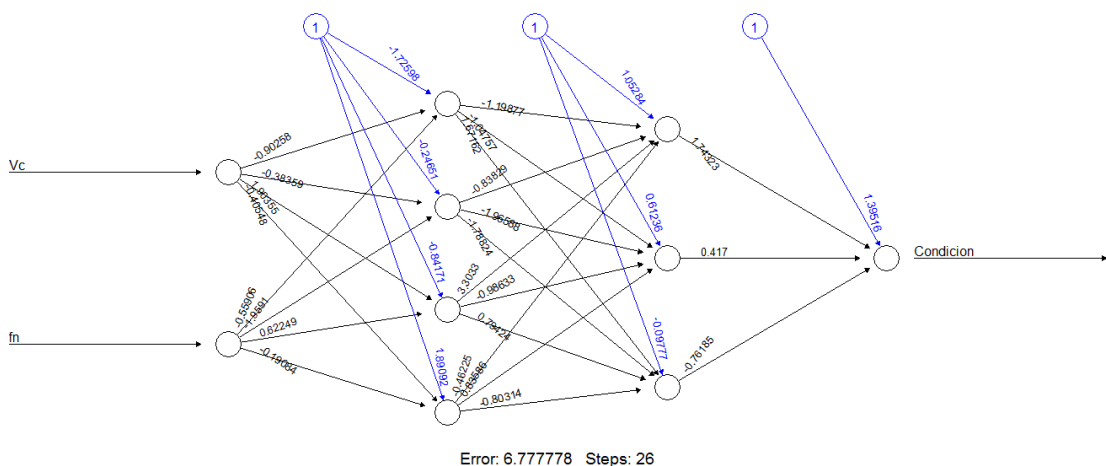
#### 3.2.4.2.1. Estructura Vc, fn y ap



**Figura 68.** Arquitectura Vc-fn-ap, AA 7075 T6

En la Figura 68 se presenta la primera condición de la arquitectura para la red neuronal del material AA 7075 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc, fn y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 6.78%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Muy buena”.

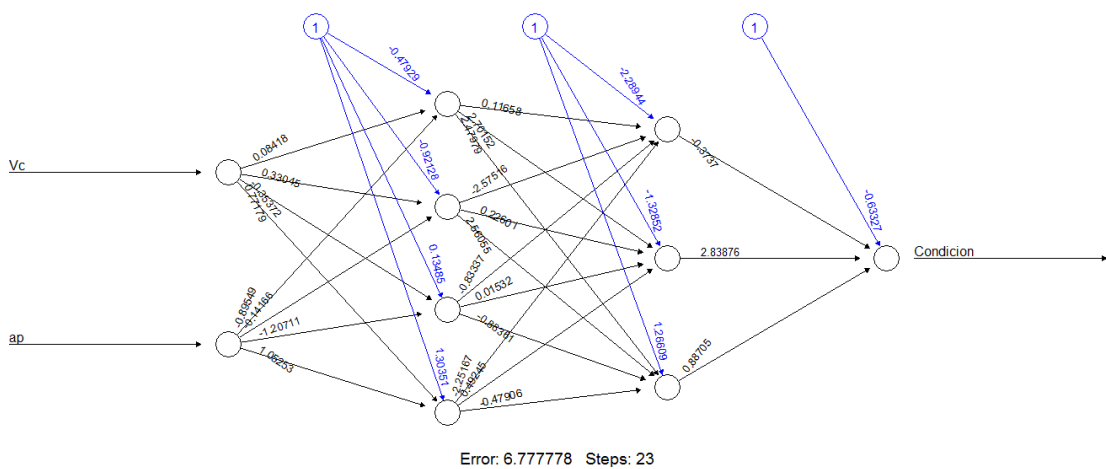
#### 3.2.4.2.2. Estructura Vc y fn



**Figura 69.** Arquitectura Vc-fn, AA 7075 T6

En la Figura 69 se presenta la segunda condición de la arquitectura para la red neuronal del material AA 7075 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc y fn, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 6.78%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Muy buena”.

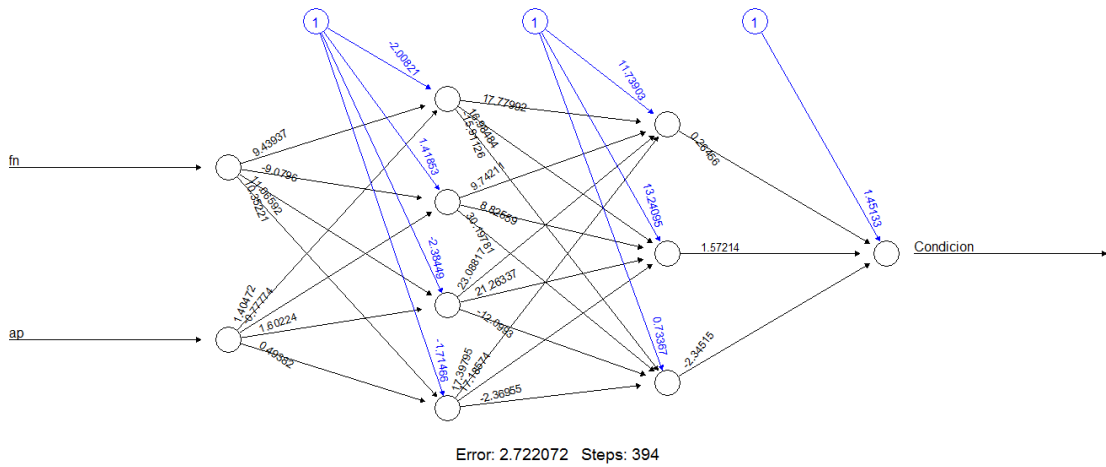
### 3.2.4.2.3. Estructura Vc y ap



**Figura 70.** Arquitectura Vc-ap, AA 7075 T6

En la Figura 70 se presenta la tercera condición de la arquitectura para la red neuronal del material AA 7075 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 6.78%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Muy buena”.

#### 3.2.4.2.4. Estructura fn y ap




**Figura 71.** Arquitectura fn-ap, AA 7075 T6

En la Figura 71 se presenta la cuarta condición de la arquitectura para la red neuronal del material AA 7075 T6. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables fn y ap, las dos siguientes capas tienen 4 y 3 neuronas respectivamente para cumplir la condición de salida y un error del 2.72%. Para este caso se tiene una precisión del 0% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Regular” pero la predicción fue de etiqueta “Muy buena”.

#### 3.2.4.3. Análisis combinado de aluminios AA 6061 T6 y AA 7075 T6

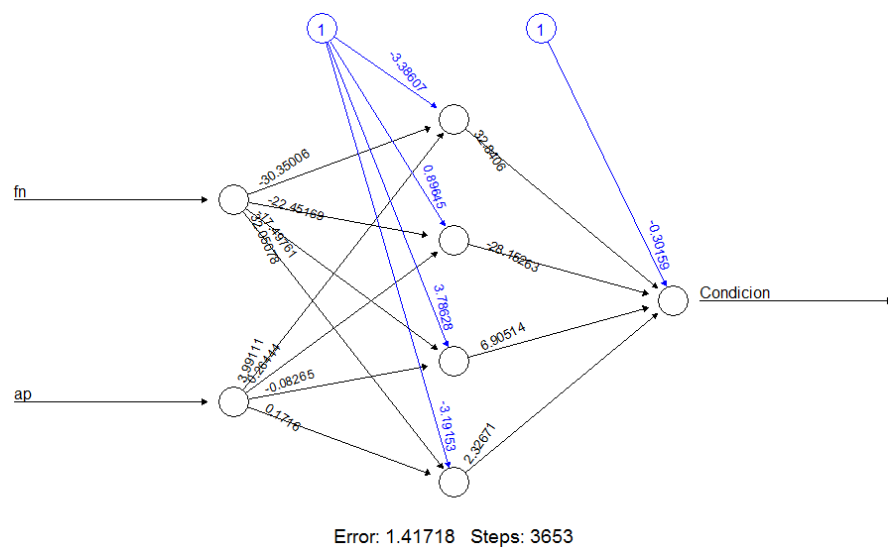
##### 3.2.4.3.1. Estructura Vc, fn y ap



**Figura 72.** Arquitectura Vc-fn-ap

En la Figura 72 se presenta la primera condición de la arquitectura para la red neuronal del análisis conjunto de ambas aleaciones de aluminio. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc, fn y ap, las dos siguientes capas tienen 2 y 4 neuronas respectivamente para cumplir la condición de salida y un error del 23.25%. Para este caso se tiene una precisión del 25% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Excelente” pero una predicción acertó, el otro fallo y predijo con etiqueta “Muy buena” y las otras dos predicciones restantes las señalo con “Regular”.


#### 3.2.4.3.2. Estructura fn y ap



**Figura 73.** Arquitectura fn-ap

En la Figura 73 se presenta la segunda condición de la arquitectura para la red neuronal del análisis conjunto de ambas aleaciones de aluminio. La ANN tiene 3 capas, la primera capa se consideró de entrada las variables fn y ap, la siguiente capa tiene 4 neuronas respectivamente para cumplir la condición de salida y un error del 1.42%. Para este caso se tiene una precisión del 75% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Excelente” pero una predicción acertó y el otro fallo, la otra referencia fue la etiqueta “Regular” y acertó las 2 predicciones.

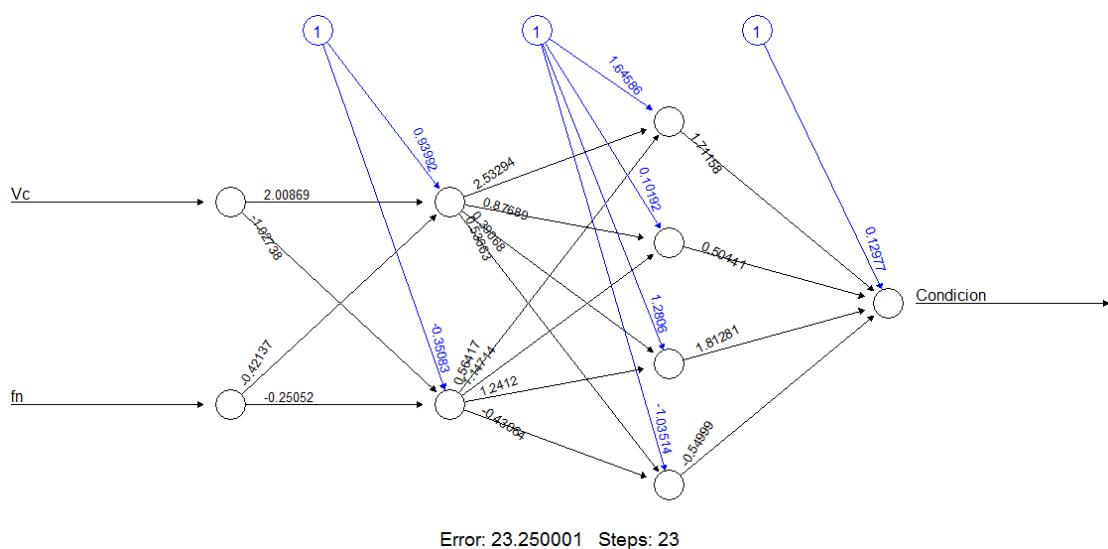
### 3.2.4.3.3. Estructura Vc y ap



**Figura 74.** Arquitectura Vc-ap

En la Figura 74 se presenta la tercera condición de la arquitectura para la red neuronal del análisis conjunto de ambas aleaciones de aluminio. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables Vc y ap, las dos siguientes capas tienen 2 y 4 neuronas respectivamente para cumplir la condición de salida y un error del 23.25%. Para este caso se tiene una precisión del 25% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Excelente” pero una predicción acertó y las otras predicciones fallo seleccionando una etiqueta “Muy buena” y las otras dos etiquetas como “Regular”.

### 3.2.4.3.4. Estructura Vc y fn



**Figura 75.** Arquitectura Vc-fn

En la Figura 75 se presenta la cuarta condición de la arquitectura para la red neuronal del análisis conjunto de ambas aleaciones de aluminio. La ANN tiene 4 capas, la primera capa se consideró de entrada las variables  $V_c$ ,  $f_n$  y  $a_p$ , las dos siguientes capas tienen 2 y 4 neuronas respectivamente para cumplir la condición de salida y un error del 23.25%. Para este caso se tiene una precisión del 25% debido que en la predicción de instancias se tomó de referencia observaciones de etiqueta “Muy buena” pero una predicción acertó, el otro fallo y predijo con etiqueta “Excelente” y las otras dos predicciones restantes las señalo con “Regular”.

### 3.2.5. Análisis de financiero

#### 3.2.5.1. Costo de mecanizado

En el análisis del costo de mecanizado, se considera el valor del costo general y de consumo energético; el costo de los insertos de corte no se agrega porque ya consta en el precio de los materiales y el valor del sistema de refrigeración no se estimó porque el estudio se hizo sin aceite de corte.

$$C_T = C_e + C_o \quad [31]$$

Para analizar el costo del consumo energético, se utilizó la Ecuación 21 y los resultados de los ensayos de la Tabla 8; se tiene la Tabla 11 de costos en función de los tiempos de mecanizado, que sumadas todas las instancias da un resultado total de 8.97 dólares americanos [106].

**Tabla 11.** Costo de consumo energético

Ensayo	Tiempo [s]	Costo [\$]
1	155,41	1,61
2	62,23	0,64
3	43,04	0,44
4	59,75	0,62
5	32,72	0,34
6	28,44	0,29
7	34,52	0,36
8	21,43	0,22
9	17,23	0,18
10	117,95	1,22
11	62,33	0,64

Continuación de Tabla 10. Costo de consumo energético

12	44,27	0,46
13	61,49	0,64
14	33,86	0,35
15	24,40	0,25
16	30,57	0,32
17	19,73	0,20
18	18,75	0,19

Para determinar los costos de operación se considera el valor del operador cualificado en la operación; actualmente en el Ecuador el costo hora de un operador es 2.50 dólares americanos que trabajando las 10 horas en el alquiler de la maquina CNC genera un costo de 25.00 dólares americanos.

Para establecer el valor de las luminarias en el ambiente de mecanizado se utiliza la Ecuación 24; utilizando 6 focos de 120 watts en un tiempo de 10 horas; costara 3.36 dólares americanos.

Para fijar el valor de la depreciación de la maquina se utilizará la Ecuación 26 en función de las horas utilizadas para mecanizar los ensayos; depreciándose un costo de 12.5 dólares americanos.

El costo total del mecanizado para el estudio será de 49.83 dólares americanos.

### 3.2.5.2.Costo de materiales

En la Tabla 12 se exhibe el costo de los materiales necesarios para realizar la investigación, sumando un total de 260.85 dólares americanos.

**Tabla 12.** Costo de materiales

<b>Materiales</b>	<b>Cantidad</b>	<b>Valor [\$]</b>	<b>Valor total [\$]</b>
Porta inserto MDJNR 2020 K1504	1	42.00	42.00
Eje de aluminio AA 7075 T6, diametro 60	1	30.00	30.00
Eje de aluminio AA 6061 T6, diametro 65	1	39.00	39.00
Inserto de corte DCGX 11T304-AL H10 (CVD)	5	10.00	50.00
Inserto de corte DCGX 11T304-AL H10 (PVD)	5	10.00	50.00
Inserto de corte DNMG 150404 – HM NC3020	5	9.97	49.85

### 3.2.5.3.Costo directo

El valor incurrido en el estudio del mecanizado de la investigación se resume en la Tabla 13, resultando un costo total de 1175.85 dólares americanos.

**Tabla 13.** Costo directo

<b>Actividad</b>	<b>Tiempo [h]</b>	<b>Costo hora [\$/h]</b>	<b>Costo total [\$]</b>
Recopilación de datos	10	3,40	34,00
Análisis de pruebas	47	3,00	141,00
Ingreso de datos	30	3,00	90,00
Procesamiento de información	60	3,50	210,00
Evaluación de la programación	20	3,50	70,00
Documentación de resultados	150	1,00	150,00
Impresiones, anillados y empastado	N.A.	N.A.	20,00
Herramientas para la experimentación	N.A.	N.A.	200,00
Materiales para la experimentación	N.A.	N.A.	260,85

### 3.2.5.4.Costo indirecto

Para ciertos procedimientos la universidad proporciona de su laboratorio de mecanizado la instrumentaría necesaria para el proceso; sin embargo, de ser el caso de no tener la universidad los instrumentos necesarios, se tomará el valor de alquiler. El costo indirecto total expuesto en la Tabla 14 es de 700.00 dólares americanos.

**Tabla 14.** Costo indirecto

<b>Actividad</b>	<b>Tiempo [h]</b>	<b>Costo hora [\$/h]</b>	<b>Costo total [\$]</b>
Horas maquina Torno CNC	10	20,00	200,00
Rugosímetro	20	15,00	300,00
Instrumentos de medición	20	10,00	200,00

### 3.2.5.5.Costo total

Para el proyecto de investigación es costo del estudio y desarrollo es de 1925.68 dólares americanos.



## CONCLUSIONES

1. La rugosidad se relaciona 96.7% con el avance, 60.3% con el caudal de material evacuado, 13% con la profundidad, 8% con el tipo de herramienta, 3.6% con la clase de material y relación inversa del 55.1% con el tiempo de mecanizado, como se pudo observar en la Figura 57.
2. Al analizar la integridad superficial en función de los parámetros de mecanizado, se evidencia un comportamiento periódico de los índices de la rugosidad, ocasionado por el avance.
3. Al aplicar el arreglo ortogonal para determinar el balance en el diseño de factores y niveles que se utilizaron, se pudo concluir que el valor más bajo de rugosidad es de  $0.74\text{ }\mu\text{m}$  al utilizar un avance de  $0.1\text{ mm/rev}$ , profundidad de  $0.3\text{ mm}$  e inserto DCGX (CVD); sin embargo, el valor más alto de rugosidad es de  $8.85\text{ }\mu\text{m}$  al emplear un avance de  $0.3\text{ mm/rev}$ , profundidad de  $1.2\text{ mm}$  e inserto DCGX (PVD).
4. Se pudo concluir que mientras menor sea el índice de la integridad superficial, mayor será el tiempo de mecanizado, provocando una diferencia de costo en el proceso de manufactura.

## **RECOMENDACIONES**

1. Se recomienda el uso de un arreglo ortogonal L-27 en la aplicación del análisis neuronal y censo de calificadores de rendimiento para complementar el estudio.
2. El uso del aceite de corte en procesos de manufactura presenta ventajas en parámetros como la integridad de la herramienta, enfriamiento de superficies calientes en revolución y acabado superficial; al no ser utilizado en el desarrollo del presente estudio, se podría incorporar y censar la mejora en el proceso, para comparar con la investigación desarrollada.
3. Al hacer los ensayos se realizó con herramientas nuevas; sin embargo, el inserto tras alcanzar un desgaste de 0.3 mm y posteriormente al ser rectificado, tiene diferentes propiedades; si se mecaniza con los insertos arreglados, se podría estudiar el costo beneficio generado.

## REFERENCIAS

- [1] C. Yan, M. Li, L. Wei y M. Qi, «Improved adaptive genetic algorithm for the vehicle Insurance Fraud Identification Model based on a BP Neural Network,» *Theoretical Computer Science*, vol. 817, pp. 12-23, 2020.
- [2] A. Cordovés García, A. M. Lastre Aleaga, L. L. Lorente Leyva, A. Cordovés Rodríguez, R. L. Ávila Rondón y R. Rodríguez Crespo, «Adaptación inteligente de rutas tecnológicas para piezas simétricas con cavidades mediante Razonamiento Basado en Casos,» *RISTI Revista Ibérica de Sistemas e Tecnologías de Informação*, vol. 19, pp. 632-644, 2019.
- [3] D. Ward, R. Miller y A. Nikolaev, «Evaluating three stuttering assessments through network analysis, random forests and cluster analysis,» *Journal of Fluency Disorders*, vol. 105823, 2020.
- [4] E. Biabiany, D. Bernard y V. Page, «Design of an expert distance metric for climate clustering: The case of rainfall in the Lesser Antilles,» *Computer & Geosciences*, vol. 145, 2020.
- [5] K. Kumar Sharma y A. Seal, «Clustering analysis using an adaptive fused distance,» *Engineering Applications of Artificial Intelligence*, vol. 96, 2020.
- [6] Y. Chen y L. Billard, «A study of divisive clustering with Hausdorff distances for interval data,» *Pattern Recognition*, vol. 96, 2019.
- [7] P. V. Osswald, P. Obst y G. Mazzei Capote, «Failure criterion for PA 12 multi-jet fusion additive manufactured parts,» *Additive Manufacturing*, vol. 37, 2021.
- [8] T. Chen, T. Zhang y H. Li, «Applications of laser-induced breakdown spectroscopy (LIBS) combined with machine learning in geochemical and environmental resources exploration,» *TrAC Trends in Analytical Chemistry*, vol. 133, 2020.
- [9] N. Fernandez, A. Lorenzo, M. Rickard, M. Chua, J. Pippi Salle, J. Perez, L. Braga y C. Matava, «Digital Pattern Recognition for the Identification and Classification of Hypospadias Using Artificial Intelligence vs Experienced Pediatric Urologist,» *Urology*, vol. 147, pp. 264-269, 2021.
- [10] A. Aziz Kalteh y S. Babouei, «Control chart patterns recognition using ANFIS with new training algorithm and intelligent utilization of shape and statistical features,» *ISA Transactions*, vol. 102, pp. 12-22, 2020.
- [11] D. Singh, P. Kumar Sarangi, C. Singla y A. Kumar Sahoo, «Odia character recognition system: A study on feature extraction and classification techniques,» *Material: Proceedings*, 2020.
- [12] J. Zhang, Z. Zhang y H. Jinxiu, «Monitoring method for gasification process instability using BEE-RBFNN pattern recognition,» *International Journal of Hydrogen Energy*, vol. 46, pp. 16202-16216, 2021.
- [13] A. B. Solanki, S. S. Sunilkumar y V. Vajpayee, «Implementation of quality tools and effective strategies to boost production market standards for forged crankshafts: A case study of forging industry,» *Materialstoday: Proceedings*, 2021.

- [14] J. Kiefer, S. Allegretti y T. Breckle, «Quality- and Lifecycle-oriented Production Engineering in Automotive Industry,» *Procedia CIRP*, vol. 62, pp. 446-451, 2017.
- [15] D. Chariguaman y G. Jarrin, Artists, *Análisis de la rugosidad superficial por influencia de la velocidad y profundidad de corte en el torneado de AA7075 - T6 mecanizado en un torno CNC.* [Art]. Universidad Politecnica Salesiana, 2019.
- [16] B. V. Revanasiddesh, A. Pasha Taj, N. Kumar y B. S. Suresh, «Extraction of modal parameters of CNC lathe bed using finite element and experimental method,» *Materialstoday: Proceedings*, vol. 24, pp. 398-405, 2020.
- [17] T. Ahmed, N. Mollick, S. Mahmud y T. Ahmad, «Analysis of Effects of Machining Parameters on Cutting Force Components in Turning AISI 201 Stainless Steel Using Cemented Carbide Cutting Tool Insert,» *Materialstoday: Proceedings*, vol. 42, pp. 832-837, 2021.
- [18] Y. He, D. Silva de Vasconcellos, D. Bourrier, K. Hajdu, J. O. Durand, F. Cunin, V. Bardinal y T. Leichle, «Lateral porous silicon interferometric transducer for on-chip flow-through sensing applications,» *Sensors and Actuators A: Physical*, vol. 332, n° 113089, 2021.
- [19] N. Emminghaus, C. Hoff, J. Hermsdorf y S. Kaierle, «Residual oxygen content and powder recycling: Effects on surface roughness and porosity of additively manufactured Ti-6Al-4V,» *Additive Manufacturing*, vol. 46, n° 102093, 2021.
- [20] C. Ho Lee, D. Hee Lee, S. Hyun Choi y K. Jae Kim, «Approach to derive golden paths under time-varying machine performance in multistage manufacturing process,» *Journal of manufacturing systems*, vol. 61, pp. 77-86, 2021.
- [21] Y. Ning Sun, Z. Long Zhuang, H. Wei Xu, W. Qin y M. Jiao Feng, «Data-driven modeling and analysis based on complex network for multimode recognition of industrial processes,» *Journal of Manufacturing Systems*, 2021.
- [22] Y. Gao, X. Li, X. Vincent Wang, L. Wang y L. Gao, «A Review on Recent Advances in Vision-based Defect Recognition towards Industrial Intelligence,» *Journal of Manufacturing Systems*, 2021.
- [23] A. Caggiano, F. Napolitano y R. Teti, «Hierarchical cluster analysis for pattern recognition of process conditions in die sinking EDM process monitoring,» *Procedia CIRP*, vol. 99, pp. 514-519, 2021.
- [24] Z. Lu, M. Wang y W. Dai, «A condition monitoring approach for machining process based on control chart pattern recognition with dynamically-sized observation windows,» *Computers and Industrial Engineering*, vol. 142, n° 106360, 2020.
- [25] M. Fromhold Eisebith, P. Marschall, R. Peters y P. Thomes, «Torn between digitized future and context dependent past – How implementing ‘Industry 4.0’ production technologies could transform the German textile industry,» *Technological Forecasting and Social Change*, vol. 166, n° 120620, 2021.
- [26] J. V. Dambros, J. O. Trierweiler y M. Farenzena, «Industrial datasets and a tool for SISO control loops data visualization and analysis,» *Computers and Chemical Engineering*, vol. 145, n° 107198, 2021.

- [27] K. Jie Feng, S. Teng Liong y K. Hong Liu, «The design of variable-length coding matrix for improving error correcting output codes,» *Information Sciences*, vol. 534, pp. 192-217, 2020.
- [28] H. Yan, X. Li, M. Liu, D. Chong y J. Yan, «Performance analysis of a solar-aided coal-fired power plant in off-design working conditions and dynamic process,» *Energy Conversion and Management*, vol. 220, n° 113059, 2020.
- [29] A. FM Alkarkhi y W. AA Alqaraghuli, «Software estadístico R,» de *Estadísticas aplicadas para ciencias ambientales con R*, Ámsterdam, Países Bajos, Elsevier, 2020, pp. 11-27.
- [30] L. Li, «Real time auxiliary data mining method for wireless communication mechanism optimization based on Internet of things system,» *Computer Communications*, vol. 160, pp. 333-341, 2020.
- [31] W. Xiao y J. Hu, «Paradigm and performance analysis of distributed frequent itemset mining algorithms based on Mapreduce,» *Microprocessors and Microsystems*, vol. 82, n° 103817, 2021.
- [32] R. S. Baker, D. Gašević y S. Karumbaiah, «Four paradigms in learning analytics: Why paradigm convergence matters,» *Computers and Education: Artificial Intelligence*, vol. 2, n° 100021, 2021.
- [33] C. A. Escobar, R. Morales Menendez y D. Macias, «Process-monitoring-for-quality — A machine learning-based modeling for rare event detection,» *Array*, vol. 100034, n° 7, 2020.
- [34] K. Gao, G. Mei, F. Piccialli, S. Cuomo, J. Tu y Z. Huo, «Julia language in machine learning: Algorithms, applications, and open issues,» *Computer Science Review*, vol. 37, n° 100254, 2020.
- [35] G. M. Farinella, M. Leo, G. Medioni y M. Trivedi, «Learning and recognition for assistive computer vision,» *Pattern Recognition Letters*, vol. 137, pp. 1-2, 2020.
- [36] A. Ajagekar y F. You, «Quantum computing assisted deep learning for fault detection and diagnosis in industrial process systems,» *Computers and Chemical Engineering*, vol. 143, n° 107119, 2020.
- [37] R. Janarthanan, S. Doss y S. Baskar, «Optimized unsupervised deep learning assisted reconstructed coder in the on-nodule wearable sensor for human activity recognition,» *Measurement*, vol. 164, n° 108050, 2020.
- [38] C. D. Hubbs, C. Li, N. V. Sahinidis, I. E. Grossmann y J. M. Wassick, «A deep reinforcement learning approach for chemical production scheduling,» *Computers & Chemical Engineering*, vol. 141, n° 106982, 2020.
- [39] T. Braun, S. Spiliopoulos, C. Veltman, V. Hergesell, A. Passow, G. Tenderich, M. Borggrefe y M. Koerner, «Detection of myocardial ischemia due to clinically asymptomatic coronary artery stenosis at rest using supervised artificial intelligence-enabled vectorcardiography – A five-fold cross validation of accuracy,» *Journal of Electrocardiology*, vol. 59, pp. 100-105, 2020.
- [40] O. Khan, J. H. Badhiwala, G. Grasso y M. G. Fehlings, «Use of Machine Learning and Artificial Intelligence to Drive Personalized Medicine Approaches for Spine Care,» *World Neurosurgery*, vol. 140, pp. 512-518, 2020.

- [41] L. M. Watson, «Using unsupervised machine learning to identify changes in eruptive behavior at Mount Etna, Italy,» *Journal of Volcanology and Geothermal Research*, vol. 405, n° 107042, 2020.
- [42] H. Yu, Y. Chen, P. Lingras y G. Wang, «A three-way cluster ensemble approach for large-scale data,» *International Journal of Approximate Reasoning*, vol. 115, pp. 32-49, 2019.
- [43] Z. Cai, X. Yang, T. Huang y W. Zhu, «A new similarity combining reconstruction coefficient with pairwise distance for agglomerative clustering,» *Information Sciences*, vol. 508, pp. 173-182, 2020.
- [44] A. Baazaoui, M. Abderrahim y W. Barhoumi, «Dynamic distance learning for joint assessment of visual and semantic similarities within the framework of medical image retrieval,» *Computers in Biology and Medicine*, vol. 122, n° 103833, 2020.
- [45] S. Daneshgadeh Çakmakçı, T. Kemmerich, T. Ahmed y N. Baykal, «Online DDoS attack detection using Mahalanobis distance and Kernel-based learning algorithm,» *Journal of Network and Computer Applications*, vol. 168, n° 102756, 2020.
- [46] J. Qi, B. Chen y D. Zhang, «Multi-information fusion-based belt condition monitoring in grinding process using the improved-Mahalanobis distance and convolutional neural networks,» *Journal of Manufacturing Processes*, vol. 59, pp. 302-315, 2020.
- [47] C. Zang, J. Li, Y. Zhao, T. Li, Q. Chen y X. Zhang, «A hybrid deep learning-based method for short-term building energy load prediction combined with an interpretation process,» *Energy and Buildings*, vol. 225, n° 110301, 2020.
- [48] S. R. Blackburn, C. Homberger y P. Winkler, «The minimum Manhattan distance and minimum jump of permutations,» *Journal of Combinatorial Theory, series A*, vol. 161, pp. 364-386, 2019.
- [49] Chen y T. Yu, «New Chebyshev distance measures for Pythagorean fuzzy sets with applications to multiple criteria decision analysis using an extended ELECTRE approach,» *Expert Systems with Applications*, vol. 147, n° 113164, 2020.
- [50] H. J. Choe y M. Yang, «The Minkowski dimension of boundary singular points in the Navier–Stokes equations,» *Journal of Differential Equations*, vol. 267, pp. 4075-4718, 2019.
- [51] Y. Huang y Y. Jiang, «Variational characterization for the planar dual Minkowski problem,» *Journal of Functional Analysis*, vol. 277, pp. 2209-2236, 2019.
- [52] G. Dzemyda y M. Sabaliauskas, «Geometric multidimensional scaling: A new approach for data dimensionality reduction,» *Applied Mathematics and Computation*, n° 125561, 2020.
- [53] M. Sato Ilic, «Probabilistic Metric Based Multidimensional Scaling,» *Procedia Computer Science*, vol. 168, pp. 65-72, 2020.

- [54] J. Tenreiro Machado y A. M. Lopes, «Multidimensional scaling locus of memristor and fractional order elements,» *Journal of Advanced Research*, vol. 25, pp. 147-157, 2020.
- [55] A. Žiberna, «k-means-based algorithm for blockmodeling linked networks,» *Social Networks*, vol. 61, pp. 153-169, 2020.
- [56] Y. Wang, S. Gao, Y. Yu, Z. Cai y Z. Wang, «A gravitational search algorithm with hierarchy and distributed framework,» *Knowledge Based Systems*, vol. 218, n° 106877, 2021.
- [57] Z. Xu, J. Homer Saleh y R. Subagia, «Machine learning for helicopter accident analysis using supervised classification: Inference, prediction, and implications,» *Reliability Engineering & System Safety*, vol. 204, n° 107210, 2020.
- [58] W. Yang, H. Long, L. Ma y H. Sun, «Research on Clustering Method Based on Weighted Distance Density and K-Means,» *Procedia Computer Science*, vol. 166, pp. 507-511, 2020.
- [59] B. Beer, M. Jimenez Bartolome, L. Berndorfer, G. Bochmann, G. M. Guebitz y G. Nyanhongo, «Controlled enzymatic hydrolysis and synthesis of lignin cross-linked chitosan functional hydrogels,» *International Journal of Biological Macromolecules*, vol. 161, pp. 1440-1446, 2020.
- [60] N. Ali, B. Viggiano, M. Tutkun y R. Bayoan Cal, «Cluster-based reduced-order descriptions of two phase flows,» *Chemical Engineering Science*, vol. 222, n° 115660, 2020.
- [61] A. Afzal, A. Aabid, S. A. Khan, U. Rajak, T. Nath Verma y R. Kumar, «Response surface analysis, clustering, and random forest regression of pressure in suddenly expanded high-speed aerodynamic flows,» *Aerospace Science And Technology*, vol. 107, n° 106318, 2020.
- [62] J. Zhao, y. Li, C. Wang, H. Zhang, H. Zhang, B. Jiang, X. Guo y X. Song, «IRESbase: A Comprehensive Database of Experimentally Validated Internal Ribosome Entry Sites,» *Genómica, proteómica y bioinformática*, vol. 18, pp. 129-139, 2020.
- [63] J. Park, K. Vin Park, S. Yoo, S. Ok Choi y S. Won Han, «Development of the WEEE grouping system in South Korea using the hierarchical and non-hierarchical clustering algorithms,» *Resources, Conservation and Recycling*, vol. 161, n° 104884, 2020.
- [64] S. Zafari, M. Murashkina, T. Eerola, J. Sampo, H. Kalviainen y H. Haario, «Resolving overlapping convex objects in silhouette images by concavity analysis and Gaussian process,» *Journal of Visual Communication and Image Representation*, vol. 73, n° 102962, 2020.
- [65] S. Quan, J. Ma, T. Ma, F. Hu y B. Fang, «Representing local shape geometry from multi-view silhouette perspective: A distinctive and robust binary 3D feature,» *Signal Processing: Image Communication*, vol. 65, pp. 67-80, 2018.
- [66] X. Chang, H. Li, A. Kalet y D. Yang, «Development and Validation of a Bayesian Network Method to Detect External Beam Radiation Therapy

- Physician Order Errors,» *International Journal Of Radiation Oncology Biology Physics*, vol. 105, pp. 423-431, 2019.
- [67] M. Bongers, A. Karhade, J. Villavieja, O. Groot, M. Bilsky, I. Laufer y J. Schwab, «Does the SORG algorithm generalize to a contemporary cohort of patients with spinal metastases on external validation?,» *The Spine Journal*, vol. 20, pp. 1646-1652, 2020.
  - [68] F. Kayaalp y P. Erdogmus, «Benchmarking the Clustering Performances of Evolutionary Algorithms: A Case Study on Varying Data Size,» *IRBM*, vol. 41, pp. 267-275, 2020.
  - [69] O. Özdenizci y D. Erdoğan, «Stochastic mutual information gradient estimation for dimensionality reduction networks,» *Information Sciences*, vol. 570, pp. 298-305, 2021.
  - [70] L. Gao y W. Wu, «Relevance assignment feature selection method based on mutual information for machine learning,» *Knowledge Based Systems*, vol. 209, n° 106439, 2020.
  - [71] J. Ramon Cano, P. A. Gutierrez, B. Krawczyk, M. Wozniak y S. Garcia, «Monotonic classification: An overview on algorithms, performance measures and data sets,» *Neurocomputing*, vol. 341, pp. 168-182, 2019.
  - [72] C. Bishop, *Pattern Recognition and Machine Learning*, Edimburgo: Springer, 2006.
  - [73] T. Segaran, *Programming Collective Intelligence*, O'Reilly Media, Inc., 2007.
  - [74] S. Wang, Y. Zhang, C. Zhang y M. Yang, «Improved artificial neural network method for predicting photovoltaic output performance,» *Global Energy Interconnection*, vol. 3, n° 6, pp. 553-561, 2020.
  - [75] G. Alam, I. Ihsanullah, M. Naushad y M. Sillanpaa, «Applications of artificial intelligence in water treatment for optimization and automation of adsorption processes: Recent advances and prospects,» *Chemical Engineering Journal*, vol. 427, n° 130011, 2022.
  - [76] C. Guan, J. Mou y Z. Jiang, «Artificial intelligence innovation in education: A twenty-year data-driven historical analysis,» *International Journal of Innovation Studies*, vol. 4, n° 4, pp. 134-147, 2020.
  - [77] y. Wang, L. Wang, F. Yang, W. Di y Q. Chang, «Advantages of direct input-to-output connections in neural networks: The Elman network for stock index forecasting,» *Information Sciences*, vol. 547, pp. 1066-1079, 2021.
  - [78] M. Penconek, «Decision making model based on attractor network with binary neurons,» *Procedia Computer Science*, vol. 176, pp. 1930-1939, 2020.
  - [79] G. Zhou, H. Moayed, M. Bahiraei y Z. Lyu, «Employing artificial bee colony and particle swarm techniques for optimizing a neural network in prediction of heating and cooling loads of residential buildings,» *Journal of Cleaner Production*, vol. 254, n° 120082, 2020.
  - [80] X. Wang, X. Lin y X. Dang, «Supervised learning in spiking neural networks: A review of algorithms and evaluations,» *Neural Networks*, vol. 125, pp. 258-280, 2020.



- [81] Y. Zhang, A. Chen, Y. Tang, J. Dang y G. Wang, «Plaintext-related image encryption algorithm based on perceptron-like network,» *Information Science*, vol. 526, pp. 180-202, 2020.
- [82] Q. Wu y Z. Ji, «A perceptron-based replication scheme for managing the shared last level cache,» *Microprocessors and Microsystems*, vol. 85, n° 104310, 2021.
- [83] B. Bengherbia, R. Kara, A. Toubal, M. Ould Zmirli, S. Chadli y P. Wira, «FPGA implementation of a wireless sensor node with a built-in ADALINE neural network coprocessor for vibration analysis and fault diagnosis in machine condition monitoring,» *Measurement*, vol. 163, n° 107960, 2020.
- [84] J. J. Langille y C. R. Gallistel, «Locating the engram: Should we look for plastic synapses or information-storing molecules?,» *Neurobiology of Learning and Memory*, vol. 169, n° 107164, 2020.
- [85] S. J. Oks, S. Zollner, M. Jalowski, J. Fuchs y K. M. Moslein, «Embedded vision device integration via OPC UA: Design and evaluation of a neural network-based monitoring system for Industry 4.0,» *Procedia CIRP*, vol. 100, pp. 43-48, 2021.
- [86] J. Leipzig, D. Nust, C. Tapley Hoyt, K. Ram y J. Greenberg, «The role of metadata in reproducible computational research,» *Patterns*, vol. 2, n° 100322, 2021.
- [87] Y. Ogasawara y M. Kon, «Two clustering methods based on the Ward's method and dendrograms with interval-valued dissimilarities for interval-valued data,» *International Journal of Approximate Reasoning*, vol. 129, pp. 103-121, 2021.
- [88] R. Kaminsky, N. Shakhovska, N. Kryvinska y M. Younas, «Dendrograms-based disclosure method for evaluating cluster analysis in the IoT domain,» *Computers and Industrial Engineering*, vol. 158, n° 107402, 2021.
- [89] L. Ning Li, X. Feng Liu, F. Yang, W. Ming Xu, J. Yu Wang y R. Shu, «A review of artificial neural network based chemometrics applied in laser-induced breakdown spectroscopy analysis,» *Spectrochimica Acta Part B: Atomic Spectroscopy*, vol. 180, n° 106183, 2021.
- [90] Q. Chen, R. Jia y S. Pang, «Deep long short-term memory neural network for accelerated elastoplastic analysis of heterogeneous materials: An integrated data-driven surrogate approach,» *Composite Structures*, vol. 264, n° 113688, 2021.
- [91] A. Jha, K. Myers, n. Obuchowski, Z. Liu, A. Rahman, s. Babak, A. Rahmin y B. Siegel, «Objective Task-Based Evaluation of Artificial Intelligence-Based Medical Imaging Methods:: Framework, Strategies, and Role of the Physician,» *PET Clinics*, vol. 16, n° 4, pp. 493-511, 2021.
- [92] M. Sestak, M. Hericko, T. Welzer Druzovec y M. Turkanovic, «Applying k-vertex cardinality constraints on a Neo4j graph database,» *Future Generation Computer Systems*, vol. 115, pp. 459-474, 2021.
- [93] V. Ozornova y M. Rovelli, «Nerves of 2-categories and 2-categorification of  $(\infty, 2)$ -categories,» *Advances in Mathematics*, vol. 391, n° 107948, 2021.

- [94] H. Weng, Y. Xu, J. Chen, C. Ruan, L. Liang y X. Ju, «An enhanced greedy algorithm for failure resistant material design with application to composite delamination,» *Composite Structures*, vol. 278, 2021.
- [95] K. Balasubramanian y N. Ananthamoorthy, «Glaucoma classification based on intra-class and extra-class discriminative correlation and consensus ensemble classifier,» *Technovation*, vol. 112, pp. 3089-3096, 2021.
- [96] L. Goff, A. Sloodman, T. Cavailhes y E. Ducassou, «On the architecture of intra-formational Mass-Transport Deposits: Insights from the carbonate slopes of Great Bahama Bank and the Apulian Carbonate Platform,» *Marine Geology*, vol. 427, 2020.
- [97] G. Aydemir y B. Acar, «Anomaly monitoring improves remaining useful life estimation of industrial machinery,» *Journal of Manufacturing Systems*, vol. 56, pp. 463-469, 2020.
- [98] N. Milan, M. Sorgato, P. Parenti, M. Annoni y G. Lucchetta, «Effects of micromilled NiP mold surface topography on the optical characteristics of injection molded prismatic retroreflectors,» *Precision Engineering*, vol. 61, pp. 126-135, 2020.
- [99] I. Cherif, T. Dorlin, B. MARcon, G. Fromentin y H. Karaouni, «Phenomenological study of chip flow/formation and unified cutting force modelling during Ti6Al4V alloy turning operations,» *Procedia CIRP*, vol. 77, pp. 351-254, 2018.
- [100] P. Chougule, S. Kumar y H. Raval, «Relating Product Manufacturing Decisions to Environmental and Cost Performance Using CAPP,» *Procedia MAterials Science*, vol. 6, pp. 476-481, 2014.
- [101] J. Wang, P. Du, Y. Hao, Y. Ma, T. Niu y W. Yang, «An innovative hybrid model based on outlier detection and correction algorithm and heuristic intelligent optimization algorithm for daily air quality index forecasting,» *Journal of Environmental Management*, vol. 255, 2020.
- [102] V. Chenrayan, C. Manivannan, S. Velappan, K. Shahapurkar, M. Elahi, Y. Khan, A. Elfasakhany, R. Kumar y C. Pruncu, «Experimental assessment on machinability performance of CNT and DLC coated HSS tools for hard turning,» *Diamond and Related Materials*, vol. 119, 2021.
- [103] M. Muhammad, P. Frye, J. Simsiriwong, S. Shao y N. Shamsaei, «An investigation into the effects of cyclic strain rate on the high cycle and very high cycle fatigue behaviors of wrought and additively manufactured Inconel 718,» *International Journal of Fatigue*, vol. 144, 2021.
- [104] Z. Li, Q. Yan y K. Tang, «Multi-pass adaptive tool path generation for flank milling of thin-walled workpieces based on the deflection constraints,» *Journal of Manufacturing Processes*, vol. 68, pp. 690-705, 2021.
- [105] A. Md Abdullah, U. T. Khan y M. M. Krol, «Subsurface transport of carboxymethyl cellulose (CMC)-stabilized nanoscale zero valent iron (nZVI): Numerical and statistical analysis,» *Journal of Contaminant Hydrology*, vol. 243, n° 103870, 2021.

- [106] K. G. munish, Q. Song, Z. Liu, M. Sarikaya, M. Jamil, M. Mozammel, V. Kushvana, A. S. Kumar y L. Zhixiong, «Ecological, economical and technological perspectives based sustainability assessment in hybrid-cooling assisted machining of Ti-6Al-4 V alloy,» vol. 26, n° 218, 2020.

## **ANEXOS**

**Anexo 1.** Flujograma de la metodología 1 de 3

**Anexo 2.** Flujograma de la metodología 2 de 3

**Anexo 3.** Flujograma de la metodología 3 de 3

**Anexo 4.** Inserto DCGX 11T304 – AL H10 VCD

**Anexo 5.** Inserto DCGX 11T304 – AL H10 PCD

**Anexo 6.** Porta inserto SDJCR 2020 K11

**Anexo 7.** Inserto DNMG 150404 – HM NC3020

**Anexo 8.** Porta inserto MDJNR 2020K 1504

**Anexo 9.** Eje para mecanizar probetas AA 6061 T6

**Anexo 10.** Eje para mecanizar probetas AA 6061 T6

**Anexo 11.** Dimensiones probeta 1

**Anexo 12.** Dimensiones probeta 2

**Anexo 13.** Dimensiones probeta 3

**Anexo 14.** Dimensiones probeta 4

**Anexo 15.** Dimensiones probeta 5

**Anexo 16.** Dimensiones probeta 6

## Anexo 17. Dimensiones probeta 7

## Anexo 18. Dimensiones probeta 8

## Anexo 19. Dimensiones probeta 9

## Anexo 20. Parámetros de mecanizado en EasyCycle Turn

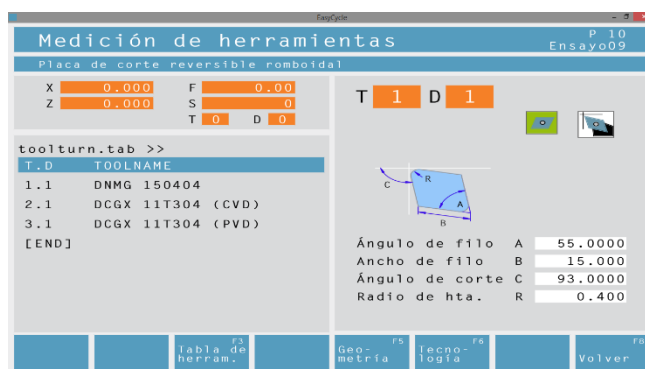


Figura 76. Configuración de herramienta DNMG

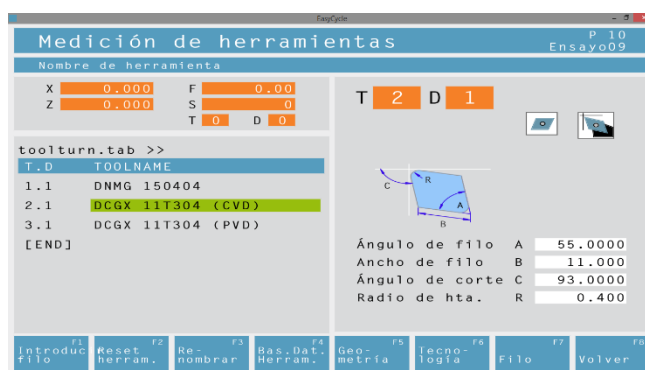


Figura 77. Configuración de herramienta DCGX (CVD)



Figura 78. Configuración de herramienta DCGX (PVD)



Figura 79. Listado de ensayos

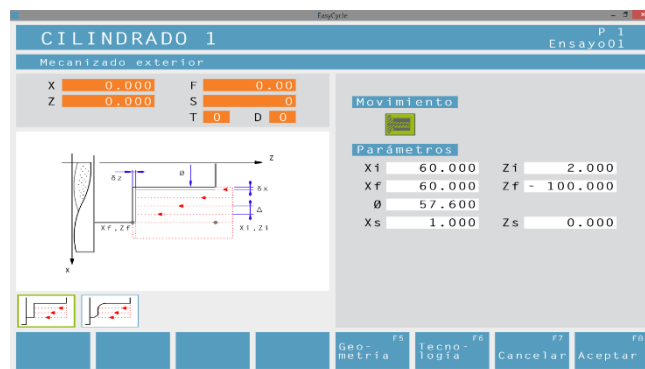


Figura 80. Geometría del ensayo 1

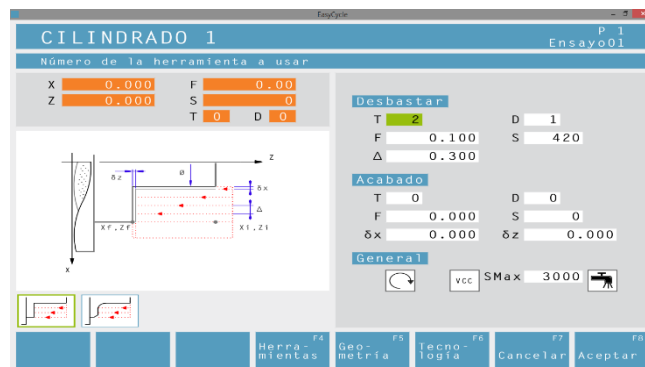


Figura 81. Tecnología del ensayo 1

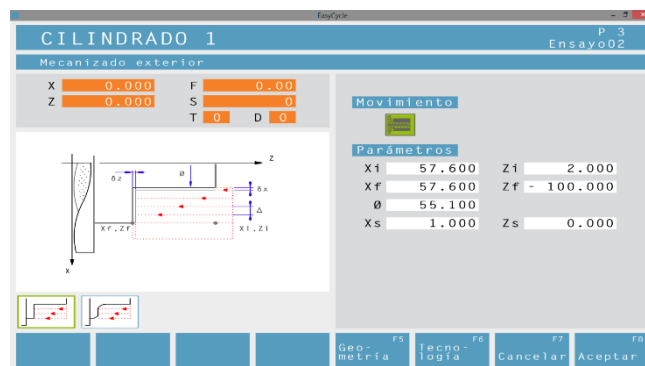
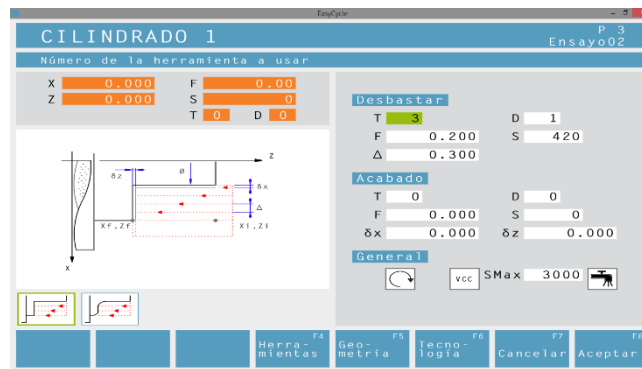
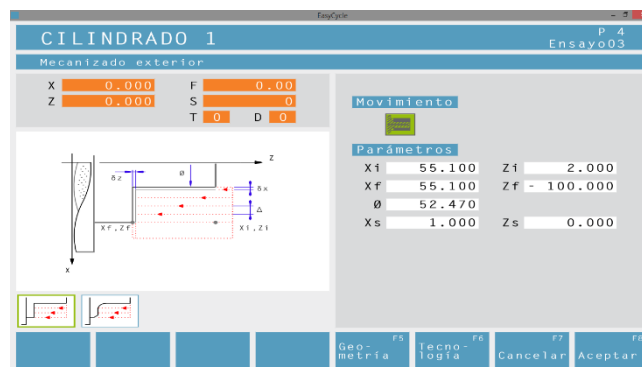


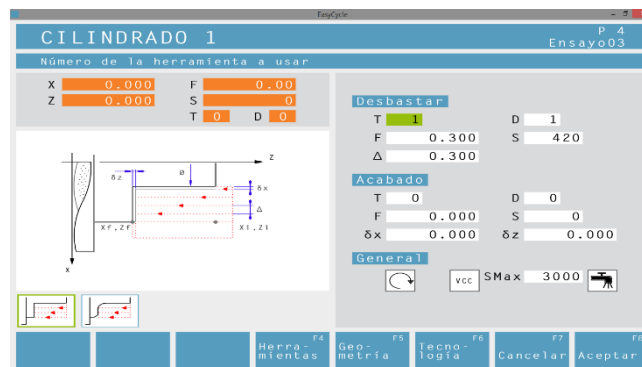
Figura 82. Geometría del ensayo 2



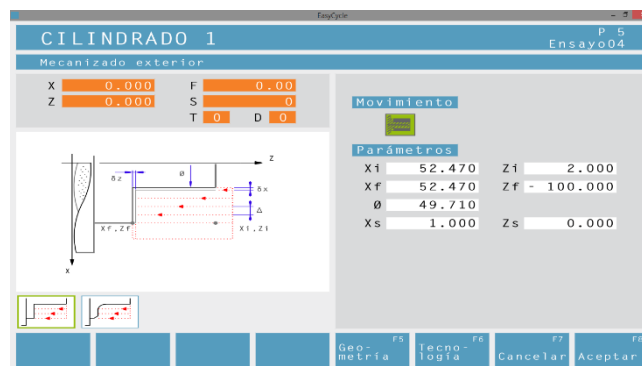
**Figura 83. Tecnología del ensayo 2**



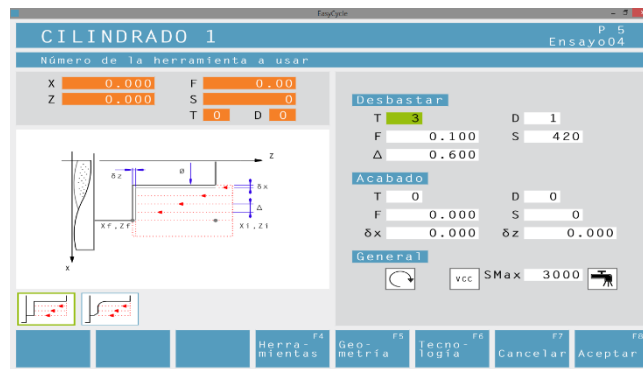
**Figura 84. Geometría del ensayo 3**



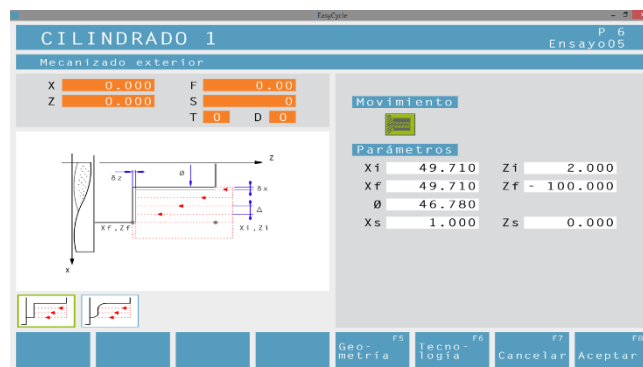
**Figura 85. Tecnología del ensayo 3**



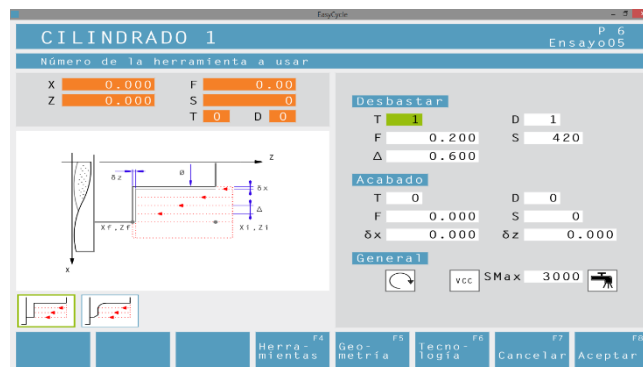
**Figura 86. Geometría del ensayo 4**



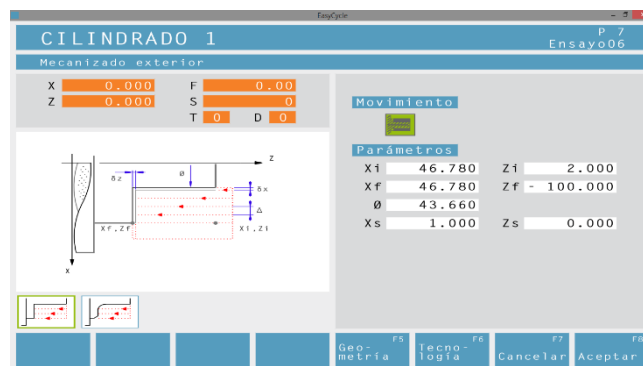
**Figura 87.** Tecnología del ensayo 4



**Figura 88.** Geometría del ensayo 5

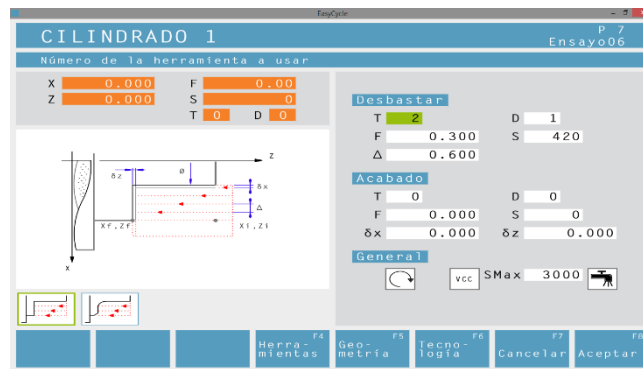


**Figura 89.** Tecnología del ensayo 5

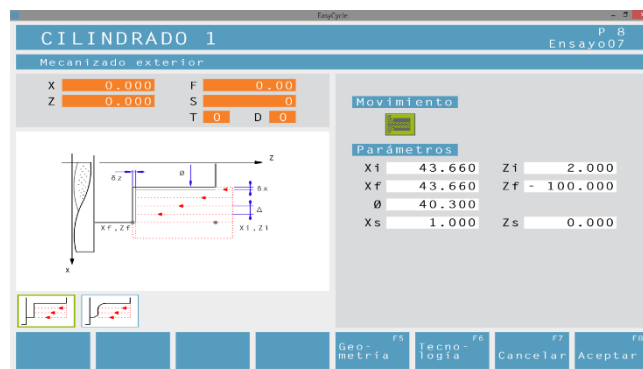


**Figura 90.** Geometría del ensayo 6

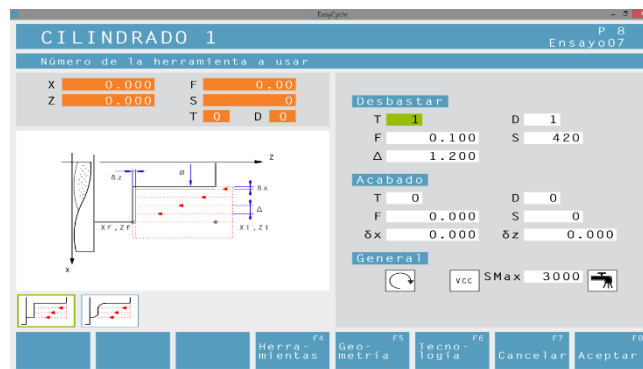




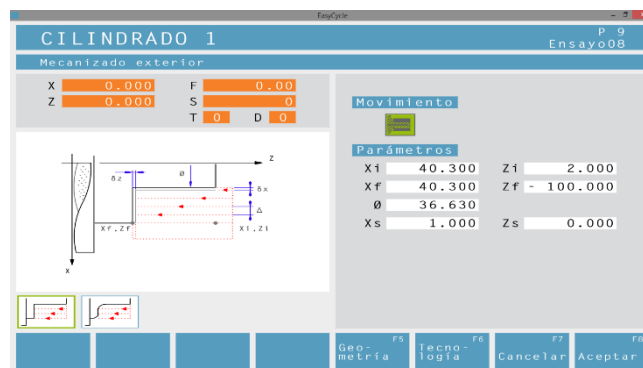
**Figura 91.** Tecnología del ensayo 6



**Figura 92.** Geometría del ensayo 7



**Figura 93.** Tecnología del ensayo 7



**Figura 94.** Geometría del ensayo 8

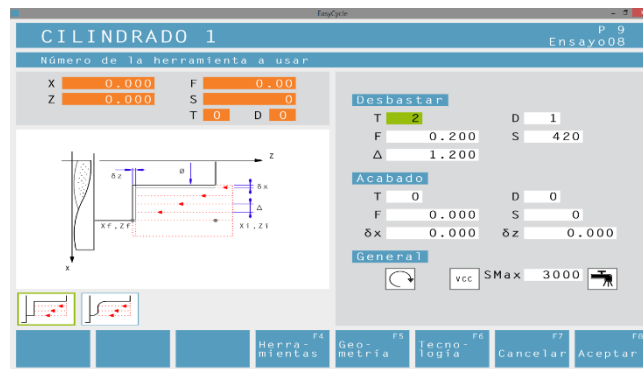


Figura 95. Tecnología del ensayo 8

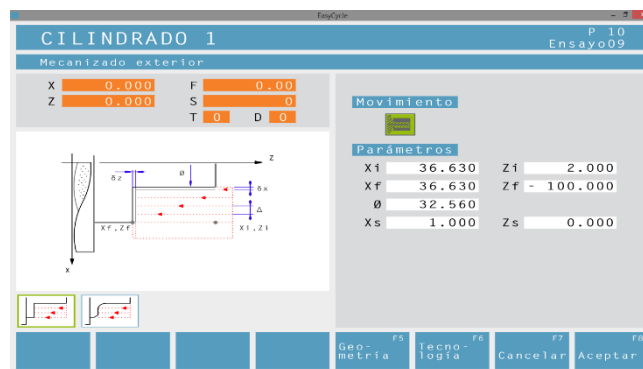


Figura 96. Geometría del ensayo 9

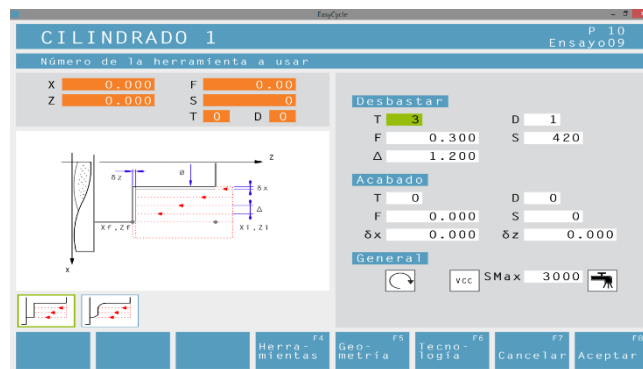




Figura 97. Tecnología del ensayo 9


**Anexo 21.** Puntos de censo de rugosidad en la probeta



**Figura 98.** Primer punto de medición de rugosidad



**Figura 99.** Segundo punto de medición de rugosidad



**Figura 100.** Tercer punto de medición de rugosidad

## Anexo 22. Matriz de confusión de la arquitectura neuronal

```
> con
Confusion Matrix and Statistics

              Reference
Prediction  Baja Buena Excelente Muy buena Regular
Baja        0    0          0          0          0
Buena       0    0          0          0          0
Excelente   0    0          0          0          2
Muy buena   0    0          0          0          0
Regular     0    0          0          0          0

Overall Statistics

          Accuracy : 0
          95% CI : (0, 0.8419)
    No Information Rate : 1
    P-Value [Acc > NIR] : 1

          Kappa : 0

  McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              NA              0
Specificity              1              1              0              1              NA
Pos Pred Value           NA              NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA              NA
Prevalence                0              0              0              0              1
Detection Rate            0              0              0              0              0
Detection Prevalence      0              0              1              0              0
Balanced Accuracy         NA              NA              NA              NA              NA
```

**Figura 101.** Matriz de confusión Vc, fn y ap - AA 6061 T6

```
> con
Confusion Matrix and Statistics

              Reference
Prediction  Baja Buena Excelente Muy buena Regular
Baja        0    0          0          0          0
Buena       0    0          0          0          0
Excelente   0    0          0          0          2
Muy buena   0    0          0          0          0
Regular     0    0          0          0          0

Overall Statistics

          Accuracy : 0
          95% CI : (0, 0.8419)
    No Information Rate : 1
    P-Value [Acc > NIR] : 1

          Kappa : 0

  McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              NA              0
Specificity              1              1              0              1              NA
Pos Pred Value           NA              NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA              NA
Prevalence                0              0              0              0              1
Detection Rate            0              0              0              0              0
Detection Prevalence      0              0              1              0              0
Balanced Accuracy         NA              NA              NA              NA              NA
```

**Figura 102.** Matriz de confusión Vc y fn - AA 6061 T6

```
> con
Confusion Matrix and Statistics

              Reference
Prediction  Baja Buena Excelente Muy buena Regular
Baja        0    0          0          0          0
Buena       0    0          0          0          0
Excelente   0    0          0          0          2
Muy buena   0    0          0          0          0
Regular     0    0          0          0          0

Overall Statistics

          Accuracy : 0
          95% CI : (0, 0.8419)
    No Information Rate : 1
    P-Value [Acc > NIR] : 1

          Kappa : 0

  McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              NA              0
Specificity              1              1              0              1              NA
Pos Pred Value           NA              NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA              NA
Prevalence                0              0              0              0              1
Detection Rate            0              0              0              0              0
Detection Prevalence      0              0              1              0              0
Balanced Accuracy         NA              NA              NA              NA              NA
```

**Figura 103.** Matriz de confusión Vc y ap - AA 6061 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Buena Excelente Muy buena Regular
Baja      0    0    0    0    0
Buena     0    0    0    0    0
Excelente 0    0    0    0    0
Muy buena 0    0    0    0    0
Regular   0    0    0    0    2

Overall Statistics

      Accuracy : 1
      95% CI : (0.1581, 1)
      No Information Rate : 1
      P-value [Acc > NIR] : 1

      Kappa : NaN

      McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              NA              1
Specificity              1              1              1              1              NA
Pos Pred Value           NA              NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA              NA
Prevalence               0              0              0              0              1
Detection Rate           0              0              0              0              1
Detection Prevalence     0              0              0              0              1
Balanced Accuracy        NA              NA              NA              NA              NA
```

**Figura 104.** Matriz de confusión fn y ap - AA 6061 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Excelente Muy buena Regular
Baja      0    0    0    0
Excelente 0    0    0    0
Muy buena 0    0    0    2
Regular   0    0    0    0

Overall Statistics

      Accuracy : 0
      95% CI : (0, 0.8419)
      No Information Rate : 1
      P-value [Acc > NIR] : 1

      Kappa : 0

      McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              0
Specificity              1              1              0              NA
Pos Pred Value           NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA
Prevalence               0              0              0              1
Detection Rate           0              0              0              0
Detection Prevalence     0              0              1              0
Balanced Accuracy        NA              NA              NA              NA
```

**Figura 105.** Matriz de confusión Vc, fn y ap - AA 7075 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Excelente Muy buena Regular
Baja      0    0    0    0
Excelente 0    0    0    0
Muy buena 0    0    0    2
Regular   0    0    0    0

Overall Statistics

      Accuracy : 0
      95% CI : (0, 0.8419)
      No Information Rate : 1
      P-value [Acc > NIR] : 1

      Kappa : 0

      McNemar's Test P-value : NA

Statistics by Class:

              Class: Baja class: Excelente class: Muy buena class: Regular
Sensitivity              NA              NA              NA              0
Specificity              1              1              0              NA
Pos Pred Value           NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA
Prevalence               0              0              0              1
Detection Rate           0              0              0              0
Detection Prevalence     0              0              1              0
Balanced Accuracy        NA              NA              NA              NA
```

**Figura 106.** Matriz de confusión Vc y fn - AA 7075 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Excelente Muy buena Regular
Baja      0      0      0      0
Excelente 0      0      0      0
Muy buena 0      0      0      2
Regular   0      0      0      0

Overall Statistics

      Accuracy : 0
      95% CI : (0, 0.8419)
      No Information Rate : 1
      P-value [Acc > NIR] : 1

      Kappa : 0

      Mcnemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              0
Specificity              1              1              0              NA
Pos Pred Value           NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA
Prevalence                0              0              0              1
Detection Rate            0              0              0              0
Detection Prevalence      0              0              1              0
Balanced Accuracy        NA              NA              NA              NA
```

**Figura 107.** Matriz de confusión Vc y ap - AA 7075 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Excelente Muy buena Regular
Baja      0      0      0      0
Excelente 0      0      0      0
Muy buena 0      0      0      2
Regular   0      0      0      0

Overall Statistics

      Accuracy : 0
      95% CI : (0, 0.8419)
      No Information Rate : 1
      P-value [Acc > NIR] : 1

      Kappa : 0

      Mcnemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              NA              0
Specificity              1              1              0              NA
Pos Pred Value           NA              NA              NA              NA
Neg Pred Value           NA              NA              NA              NA
Prevalence                0              0              0              1
Detection Rate            0              0              0              0
Detection Prevalence      0              0              1              0
Balanced Accuracy        NA              NA              NA              NA
```

**Figura 108.** Matriz de confusión fn y ap - AA 7075 T6

```
> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Buena Excelente Muy buena Regular
Baja      0      0      0      0      0
Buena     0      0      0      0      0
Excelente 0      0      1      1      2
Muy buena 0      0      0      0      0
Regular   0      0      0      0      0

Overall Statistics

      Accuracy : 0.25
      95% CI : (0.0063, 0.8059)
      No Information Rate : 0.5
      P-value [Acc > NIR] : 0.9375

      Kappa : 0

      Mcnemar's Test P-value : NA

Statistics by Class:

              Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity              NA              NA              1.00              0.00              0.0
Specificity              1              1              0.00              1.00              1.0
Pos Pred Value           NA              NA              0.25              NaN              NaN
Neg Pred Value           NA              NA              NaN              0.75              0.5
Prevalence                0              0              0.25              0.25              0.5
Detection Rate            0              0              0.25              0.00              0.0
Detection Prevalence      0              0              1.00              0.00              0.0
Balanced Accuracy        NA              NA              0.50              0.50              0.5
```

**Figura 109.** Matriz de confusión Vc, fn y ap - análisis conjunto

```

> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Buena Excelente Muy buena Regular
Baja      0    0    0    0    0
Buena     0    0    0    0    0
Excelente 0    0    1    1    0
Muy buena 0    0    0    0    0
Regular   0    0    0    0    2

Overall Statistics

      Accuracy : 0.75
      95% CI : (0.1941, 0.9937)
      No Information Rate : 0.5
      P-value [Acc > NIR] : 0.3125

      Kappa : 0.6

      McNemar's Test P-value : NA

Statistics by Class:

      Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity      NA      NA      1.0000      0.00      1.0
Specificity      1      1      0.6667      1.00      1.0
Pos Pred Value   NA      NA      0.5000      NA      1.0
Neg Pred Value   NA      NA      1.0000      0.75      1.0
Prevalence       0      0      0.2500      0.25      0.5
Detection Rate   0      0      0.2500      0.00      0.5
Detection Prevalence 0      0      0.5000      0.00      0.5
Balanced Accuracy NA      NA      0.8333      0.50      1.0

```

**Figura 110.** Matriz de confusión fn y ap - análisis conjunto

```

> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Buena Excelente Muy buena Regular
Baja      0    0    0    0    0
Buena     0    0    0    0    0
Excelente 0    0    1    1    2
Muy buena 0    0    0    0    0
Regular   0    0    0    0    0

Overall Statistics

      Accuracy : 0.25
      95% CI : (0.0063, 0.8059)
      No Information Rate : 0.5
      P-value [Acc > NIR] : 0.9375

      Kappa : 0

      McNemar's Test P-value : NA

Statistics by Class:

      Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity      NA      NA      1.00      0.00      0.0
Specificity      1      1      0.00      1.00      1.0
Pos Pred Value   NA      NA      0.25      NA      NA
Neg Pred Value   NA      NA      NA      0.75      0.5
Prevalence       0      0      0.25      0.25      0.5
Detection Rate   0      0      0.25      0.00      0.0
Detection Prevalence 0      0      1.00      0.00      0.0
Balanced Accuracy NA      NA      0.50      0.50      0.5

```

**Figura 111.** Matriz de confusión Vc y ap - análisis conjunto

```

> con
Confusion Matrix and Statistics

      Reference
Prediction Baja Buena Excelente Muy buena Regular
Baja      0    0    0    0    0
Buena     0    0    0    0    0
Excelente 0    0    0    0    0
Muy buena 0    0    1    1    2
Regular   0    0    0    0    0

Overall Statistics

      Accuracy : 0.25
      95% CI : (0.0063, 0.8059)
      No Information Rate : 0.5
      P-value [Acc > NIR] : 0.9375

      Kappa : 0

      McNemar's Test P-value : NA

Statistics by Class:

      Class: Baja Class: Buena Class: Excelente Class: Muy buena Class: Regular
Sensitivity      NA      NA      0.00      1.00      0.0
Specificity      1      1      1.00      0.00      1.0
Pos Pred Value   NA      NA      NA      0.25      NA
Neg Pred Value   NA      NA      0.75      NA      0.5
Prevalence       0      0      0.25      0.25      0.5
Detection Rate   0      0      0.00      0.25      0.0
Detection Prevalence 0      0      0.00      1.00      0.0
Balanced Accuracy NA      NA      0.50      0.50      0.5

```

**Figura 112.** Matriz de confusión Vc y fn - análisis conjunto